Lurralde : invest. espac.	45	2022	p: 57-74	ISSN 0211-5891	ISSN 1697-3070 (e)

EL INCUMPLIMIENTO CREDITICIO MEDIANTE UN ANÁLISIS COMPARATIVO DE DIFERENTES TÉCNICAS DE PREDICCIÓN EN LA GEOGRAFÍA COLOMBIANA

ARMANDO LENÍN TÁMARA AYÚS

Departamento de Finanzas. Universidad EAFIT

Escuela de Economía y Finanzas, Universidad EAFIT, Medellín (Colombia)

atamaraa@eafit.edu.co

ELIANA MARÍA PEÑALOZA MARTÍNEZ

Departamento de Finanzas. Universidad EAFIT

Escuela de Economía y Finanzas, Universidad EAFIT, Medellín (Colombia)

empenalozm@eafit.edu.co

Resumen

Bajo el enfoque del riesgo crediticio, se maneja la probabilidad de impago que un deudor tiene frente a una obligación adquirida en el pasado. El objetivo es aplicar diferentes técnicas de clasificación de aprendizaje automático, árboles de decisión, red neuronal y red bayesiana, para encontrar cuál es el mejor modelo de predicción en la adjudicación de créditos por parte de una institución financiera. A la vez, se analiza el papel de algunas variables financieras y no financieras dentro de los modelos, logrando identificar cuáles son las más influyentes. Las técnicas implementadas utilizan una base de datos conformada por 11.790 clientes pertenecientes a una entidad financiera, la cual se trabaja con una muestra de estimación de naturaleza equilibrada, segmentada en una base de entrenamiento y una de comprobación, ambas del 50% de la base total. Se concluye que los modelos tienen un gran poder de predicción; sin embargo, la técnica de árboles de decisión permite priorizar las variables por nivel de influencia sobre la probabilidad de impago.

Palabras clave: riesgo crediticio, árboles de decisión, análisis discriminante, red neuronal

KREDITUA EZ BETETZEA, KOLONBIAKO GEOGRAFIAN IRAGARTZEKO HAINBAT TEKNIKAREN ANALISI KONPARATIBOAREN BIDEZ

Laburpena

Kreditu-arriskuaren ikuspegitik, zordun batek iraganean hartutako betebehar baten aurrean ez ordaintzeko duen probabilitatea erabiltzen da. Helburua da ikaskuntza automatikoa sailkatzeko hainbat teknika aplikatzea, erabaki-zuhaitzak, sare neuronala eta sare bayestarra, finantza-erakunde batek kredituak esleitzeko orduan iragarpen-eredurik onena zein den aurkitzeko. Era berean, aldagai finantzario eta ez-finantzario batzuek ereduen barruan duten zeregina aztertzen da, eragin handiena dutenak identifikatzea lortuz. Ezarritako teknikek finantza-erakunde bateko 11.790 bezerok osatutako datu-basea erabiltzen dute. Datu-base hori estimazio-lagin orekatu batekin lantzen da, entrenamendu- eta egiaztapen-baseetan segmentatuta, eta egiaztapen-lagin batekin, biak lagina osoaren % 50ekoak. Modeloek iragartzeko ahalmen handia dutela ondorioztatzen da; hala ere, erabaki-zuhaitzen teknikak aukera ematen du eragin-mailaren araberako aldagaiak ez ordaintzeko probabilitatearen gainetik lehenesteko.

Gako-hitzak: kreditu-arriskua, erabaki-zuhaitzak, analisi diskriminatzailea, sare neuronala

CREDIT DEFAULT THROUGH A COMPARATIVE ANALYSIS OF DIFFERENT PREDICTION TECHNIQUES

Abstract

Under the credit risk approach, the probability of default that a debtor has against an obligation acquired in the past is managed. The objective is to apply different classification techniques of machine learning, decision trees, neural network, and Bayesian network, to find which is the best prediction model in the allocation of credits by a financial institution. At the same time, the role of some financial and non-financial variables within the models is analyzed, managing to identify which are the most influential. The implemented techniques use a database made up of 11,790 clients belonging to a financial institution, which is worked under an estimation sample of a balanced nature, segmented into a training base and a verification one, both of 50% of the total base. It is concluded that the models have great predictive power; however, the decision trees technique allows prioritizing the variables by level of influence on the probability of default.

Keywords: Credit risk, decision trees, discriminant analysis, neural network

PADRÃO DE CRÉDITO ATRAVÉS DE UMA ANÁLISE COMPARATIVA DE DIFERENTES TÉCNICAS DE PREVISÃO

Résumé

De acordo com a abordagem do risco de crédito, a probabilidade de inadimplência que um devedor tem contra uma obrigação adquirida no passado é administrada. O objetivo é aplicar diferentes técnicas de classificação de aprendizado de máquina, árvores de decisão, rede neural e rede Bayesiana para descobrir qual é o melhor modelo de predição na alocação de créditos por uma instituição financeira. Paralelamente, é analisado o papel de algumas variáveis financeiras e não financeiras nos modelos, conseguindo identificar quais são as mais influentes. As técnicas implementadas utilizam uma base de dados composta por 11.790 clientes pertencentes a uma instituição financeira, a qual é trabalhada sob uma amostra de estimação de carácter equilibrado, segmentada em base de formação e base de verificação, ambas de 50% da base total. Conclui-se que os modelos possuem grande poder preditivo, porém, a técnica de árvores de decisão permite priorizar as variáveis por nível de influência na probabilidade de inadimplência.

Mots clés: Risco de crédito, árvores de decisão, análise discriminante, rede neural

1. Introducción

El sistema bancario se ha convertido en el sector base de toda la economía; así lo muestran los estudios de Acosta et al. (2019) y Assef y Steiner (2020). En esta parte, juega un papel fundamental el otorgamiento del crédito como elemento primordial que impulse las inversiones en cada uno de los sectores económicos, basados en el desarrollo de proyectos, compras y fusiones efectuados por las empresas. Al mismo tiempo, el sistema crediticio se basa en la calificación crediticia asignada a las personas naturales y a las personas jurídicas; estas últimas, hacen referencia a las empresas.

Las calificaciones crediticias se convierten en el indicador que refleja el nivel de riesgo y confiabilidad de las instituciones financieras respecto al cumplimiento de las obligaciones. Es así como las agencias que evalúan y otorgan la calificación crediticia implementan en muchos casos la inteligencia artificial, basándose para ello en el comportamiento de los clientes por un largo período; sin embargo, a la hora de otorgar un crédito, las instituciones financieras no siempre poseen información referente a la calificación crediticia, puesto que a menudo la entrada inicial de las empresas al sistema financiero es única, por lo que no tienen un historial que permita otorgarles una calificación.

Por lo general, la calificación crediticia se convierte en un problema de clasificación, pero constituye a la vez una herramienta de gran poder al momento de administrar el riesgo crediticio. Estudios tales como los de Golbayani et al. (2020) y Xia et al. (2021) muestran

como la calificación permite pronosticar la probabilidad de incumpliendo en una solicitud de préstamo.

En este orden de ideas, el presente estudio pretende analizar la toma de decisión correspondiente al otorgamiento o no de un crédito sobre una empresa que no cuenta con una calificación crediticia, debido a que es la primera vez que hace dicha solicitud. Tomando como referencia los estudios de Halteh et al. (2018) y Golbayani et al. (2020), se utiliza la técnica de árboles de decisión para emitir un juicio de valor que, con base en una solidez financiera, permita argumentar la aprobación o no del crédito.

El trabajo se encuentra estructurado en el siguiente orden: en el segundo apartado, se consolida el estado del arte y se hace énfasis en las técnicas de predicción y variables predictoras utilizadas; el apartado tres muestra las metodologías utilizadas y el apartado cuatro muestra el análisis de los resultados. El apartado cinco presenta las conclusiones derivadas de los resultados obtenidos en la modelación.

2. Estudios empíricos

A lo largo del tiempo se han hecho estudios referentes al análisis del riesgo de crédito. Más aún, algunos estudios se han enfocado en comparar los resultados de las diferentes técnicas implementadas en el otorgamiento del crédito. La última década se ha caracterizado por implementar la técnica de árboles de decisión en los estudios del riesgo crediticio. Uno de estos estudios es el de Gepp et al. (2010), en el cual se aplica la técnica de árboles de decisión para predecir fallas empresariales, y se demuestra que los árboles de decisión podrían ser mejores predictores del fracaso empresarial que las técnicas tradicionales. Otro estudio es el de Wang et al. (2012), quienes ponen a prueba la técnica de árboles de decisión en torno a la calificación crediticia de los clientes de un banco, y al final encuentran que los árboles de conjunto, de estrategias duales (*RS-Bagging DT* y *Bagging-RS DT*), arrojan mejores resultados en torno a la calificación crediticia.

Ala›raj y Abbod (2016) implementan la técnica de árboles de decisión en la clasificación de los clientes, entre cumplidos e incumplidos; es decir, utilizan esta técnica para analizar y estudiar la aprobación de créditos por parte de un banco, obteniendo un nivel de acierto mayor en comparación con técnicas basadas en inteligencia artificial. Posteriormente, Halteh et al. (2018) utilizan árboles de decisión, bosques aleatorios y aumento de gradiente estocástico para calificar el riesgo de crédito, y encuentran que los indicadores de rotación de propiedad, planta y equipo, rotación de capital invertido y relación precio sobre ganancia son las variables con mejor poder explicativo en cuanto a predecir el riesgo crediticio en el sector financiero australiano.

Chopra y Bhilare (2018) analizan a través de los árboles de decisión el incumplimiento de los préstamos en el sistema bancario. Dichos resultados son confrontados con los obtenidos mediante las técnicas de análisis discriminante y regresión logística, obteniendo mejor

resultado en los árboles conjuntos que en los árboles individuales. Más adelante, Dwivedi y Tripathi (2019) diseñaron un sistema de base de conocimiento difuso, en el que definieron ocho reglas para el sistema de asignación de crédito, que implementaron en dos conjuntos de datos (alemán y australiano), logrando clasificar los datos de asignación de crédito a través de un árbol de decisión difuso. En otro estudio, Hesarzadeh (2019) muestra como tanto el rol individual, como el colectivo de una medida de calidad de información financiera (calidad) son los mismos, en el sentido de ser los mismos impactos de una medida de calidad sobre una variable dependiente, sin y con la consideración de la relación de *trade-off*/ interacción y la combinación con otras medidas de calidad.

Trivedi (2020) centra su trabajo en la construcción de un modelo de predicción de puntuación crediticia alemana, en donde se demuestra una mejor predicción con técnicas que tienen como base los árboles de decisión, como es el caso de las redes neuronales y las redes bayesianas, con lo cual se logró construir modelos de automatización para mejorar la calificación crediticia. Por otra parte, Li et al. (2020) emplean las técnicas de aprendizaje automático para predecir las calificaciones crediticias de un banco, y llegan a la conclusión de que las redes neuronales tiene un alto poder predictivo; sin embargo, para los grados especulativos los mejores son los árboles de clasificación y regresión. En complemento, Golbayani et al. (2020) aplican cuatro técnicas de aprendizaje automático a una base de datos tomada de una cartera crediticia de un banco, y los resultados muestran que los árboles de decisión son la técnica con mayor rendimiento y predicción.

Bärtl y Krummaker (2020) evalúan en su estudio cuatro técnicas de aprendizaje automático (árboles de decisión, bosques aleatorios, redes neuronales y redes neuronales probabilísticas) y la capacidad de cada una de ellas para predecir con precisión las reclamaciones de seguros de crédito a la exportación, y los árboles de decisión y las redes neuronales se desempeñaron significativamente mejor en todas las tareas de predicción. En el estudio más reciente, elaborado por Xia et al. (2021), dichos autores proponen un modelo de puntuación de crédito basado en el enfoque del árbol de decisión de aumento del gradiente de supervivencia y lo comparan con varios modelos de referencias tradicionales. Los resultados muestran que el modelo propuesto supera los puntos de referencia, en términos de predictibilidad y costo de clasificación errónea, y a la vez demuestran como la incorporación de variables macroeconómicas puede mejorar aún más el desempeño de los modelos de supervivencia.

3. Muestra

La muestra está conformada por 11.790 clientes que poseen una obligación financiera de iguales características. El período analizado comprende el período enero-diciembre de 2020, lo cual permite, tener un panorama de doce meses para las obligaciones de la base de estudio. La base de datos se distribuye entre clientes incumplidos (27%) y clientes cumplidos (73%). Al mismo tiempo, se subdivide en una base de entrenamiento (40%), comprobación (40%) y validación (20%), tal y como lo plantean los estudios de Jabeur et al. (2020), Golbayani et al. (2020), Bärtl y Krummaker (2020) y Xia et al. (2021).

Colombia se divide en seis regiones: Amazonía, Andina, Caribe, Insular, Orinoquía y Pacífica. La institución financiera objeto de estudio está ubicada en la región Andina. Según se aprecia en la ilustración 1, la institución solo presta servicios en tres de estas regiones: Caribe (35%), Andina (42%) y Pacífica (23%). Aunque se conoce la participación de los clientes en cada una de estas tres regiones, los investigadores no disponen de la ubicación geográfica de los clientes que conforman la base de datos, por lo que la localización no se pudo tomar como otra variable independiente en la búsqueda de los modelos.

Distribución de la muestra en Colombia, mapa tomado de https://mapadecolombia.org/mapa-de-colombia-con-sus-regiones.

3.1. Variable dependiente

La base de datos está segmentada en clientes cumplidos e incumplidos; los incumplidos, corresponden a una mora de más de 60 días según lo establecido por las normas internas de la institución financiera en estudio. La variable se trabaja como una binaria, donde 1 corresponde a los clientes incumplidos, y 0, a los cumplidos. Adicionalmente, se tiene un 26,8% de tasa global de malos, lo que muestra un perfil de riesgo muy alto para una institución financiera.

3.2. Variables explicativas

Tomando como referencia la información aportada por la institución financiera y los estudios de Syed Nor et al. (2019), Dwivedi y Tripathi (2019) y Trivedi (2020), las primeras variables explicativas de los modelos serán las variables financieras, que se presentan en la tabla 1.

TABLA 1. VARIABLES FINANCIERAS EXPLICATIVAS DEL MODELO

Variable	Código	Fórmula
Razón corriente	RC	Activos corrientes/pasivos corrientes
Nivel de endeudamiento	NE	(Pasivos + gastos + costos)/ingreso neto
Apalancamiento	A	Total pasivo/patrimonio
Margen neto	MN	Utilidad neta/ventas
Margen operativo	MO	Utilidad operativa/ventas
Rentabilidad operativa patrimonio	ROE	Utilidad neta/patrimonio
Rentabilidad operativa activo	ROA	Utilidad neta/total activos

Fuente: Elaboración de los autores.

Como un aporte a este campo del conocimiento, en este trabajo se utilizan algunas variables no financieras, que han sido trabajadas de manera individual en los estudios de Do Prado et al. (2019), Grundke et al. (2019) y Assef y Steiner (2020), tal como se presentan en la tabla 2.

TABLA 2. VARIABLES NO FINANCIERAS EXPLICATIVAS DEL MODELO

Variable	Código	Fórmula
Tipo	Tipo	1. S.A.S. 2. LTDA. 3. S. A. 4. Sociedad colectiva 5. Sociedad en comandita
Tamaño	Tamaño	1. Micro 2. Pequeñas 3. Medianas 4. Grandes
Edad	Edad	1. Menores de 5 años 2. Entre 5 y 10 años 3. Entre 10 y 20 años 4. Mayores de 20 años

Fuente: Elaboración de los autores.

En torno a la revisión de literatura y a las variables explicativas utilizadas en este trabajo, los investigadores plantean las siguientes hipótesis:

$H_{1:}$ Las variables financieras contienen información que permiten hacer un pronóstico confiable en términos del incumplimiento del deudor.

$H_{2:}$ Las variables no financieras (tipo, tamaño y edad) incrementan el acierto global de los modelos de incumplimiento.

H_3: Los modelos de particionamiento recursivo aportan más información que los modelos multivariables paramétricos y las herramientas de inteligencia artificial.

4. Metodologías y análisis de resultados

4.1. Árbol de decisión

Esta es una técnica basada en algoritmos de inducción de reglas, donde la mejor decisión se toma bajo una óptica probabilística. En esta ocasión se desarrolla un árbol de decisión tipo detección automática de interacciones mediante chi-cuadrado (CHAID, por sus siglas en inglés *chi-squared automatic interaction detection*), para generar un árbol no binario, y porque permite utilizar variables contínuas o categóricas, lo cual no se permite en los otros tipos de árboles de decisión.

Bajo las anteriores premisas, el árbol encontrado tiene una profundidad de 4, y muestra que la principal variable es el tamaño. Tal como puede observar en la ilustración 2, la primera

línea del árbol indica que los clientes cuyo tamaño es 1 (micro) tienden a ser incumplidos, que, en este caso, serían las microempresas; en el segundo grupo se tienen las de tamaño 2 (pequeñas), con solo un 6,16% de incumplidos, y en el tercer grupo se encuentran las de tamaño 3 (medianas) y 4 (grandes), con tan solo un 0,4% de incumplidos. Lo anterior concuerda con la lógica financiera, que establece que las empresas con mayor tamaño tienden a ser más cumplidas que las empresas de menor tamaño. Esto se basa en que el respaldo de la empresa se encuentra en mayor medida en su tamaño.

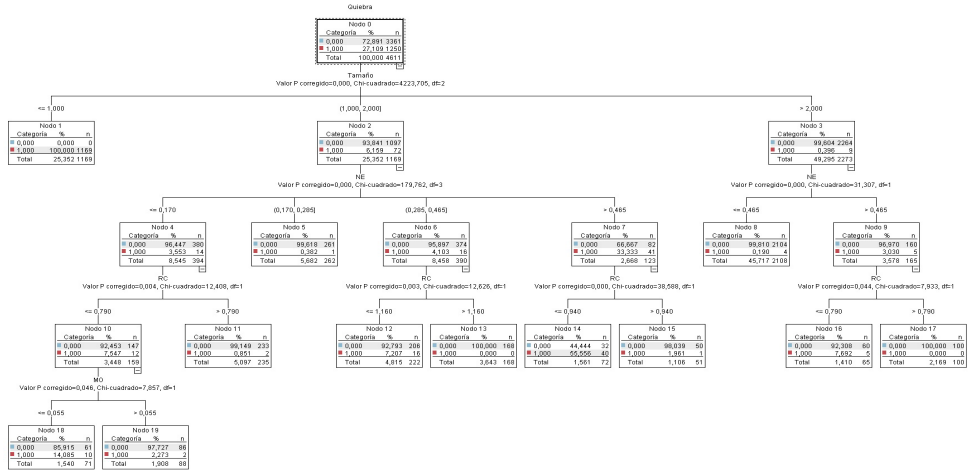

Árbol de decisión CHAID, salida IBM SPSS Modeler 18.2.

La segunda línea del árbol la determina la variable nivel de endeudamiento (NE), que ratifica lo encontrado en otros estudios, y es que aquellos clientes con nivel de endeudamiento superior al 46% tienden a ser incumplidos en el tiempo. La tercera línea muestra la razón corriente (RC), esta determina que aquellos clientes que tienen mayor liquidez son los más cumplidos. La última línea muestra la variable margen operativo (MO), en la que solo el grupo conformado por clientes de tamaño pequeño y con razón corriente menor a 0,80 están determinados por esta variable.

En torno a la importancia del predictor en cada una de las variables que hacen parte del árbol CHAID, la variable tamaño, con un 92%, es lejos la de mayor influencia; posteriormente, con una participación alrededor del 0,03%, las variables RC, NE y MO. La tabla 3 indica que, además, el árbol CHAID tiene un nivel de precisión global del 98,42% en la base de entrenamiento y 98,3% en la base de comprobación, al igual que en la base de validación.

TABLA 3. MATRIZ DE CLASIFICACIÓN ÁRBOL DE DECISIÓN

Partición	Entrenamiento		Comprobación		Validación	
Correctos	4.538	98,42%	4.741	98,3%	2.316	98,3%
Erróneos	73	1,58%	82	1,7%	40	1,7%
Total	4.611	100%	4.823	100%	2.356	100%

Fuente: Elaboración de los autores, con base en la salida de IBM SPSS Modeler 18.2.

Regresión logística

Esta técnica se basa en el desarrollo de funciones lineales y es útil para enfrentar problemas que relacionan probabilidad de ocurrencia. En este caso, el incumplimiento de los deudores. El modelo desarrollado identifica un resultado binario, que, para el caso, es incumplido o cumplido; adicionalmente se han tenido que considerar como *dummy* las variables: tipo, tamaño y edad.

El modelo obtenido se fundamenta en todas las variables explicativas planteadas en la base de datos; sin embargo, cabe anotar que las variables de más impacto son el tamaño, seguido por la edad. Por otra parte, los signos esperados en cada una de las variables ratifican lo expresado por la teoría. Así, las variables relacionadas al endeudamiento tienen signo positivo, lo que significa que dentro del modelo logístico un aumento implica una mayor probabilidad de incumplimiento. En relación con las variables de rentabilidad y liquidez, los signos dieron negativo, lo que implica que un aumento en estas variables disminuye la probabilidad de incumplimiento. En relación con las variables tamaño y edad, los resultados muestran que las empresas de mayor tamaño y edad tienden a tener menor probabilidad de incumplimiento (tabla 4).

TABLA 4. ECUACIÓN DEL MODELO DE REGRESIÓN LOGÍSTICA

Variable	β	Error estándar	Wald	Grados libertad	Sig.	Exp (β)
RC	-1,620	0,011	15,23	1	0	0,286
NE	7,875	0,001	35,26	1	0	7508,19
CE	0,093	0,002	24,10	1	0	2,629
A	0,007	0,012	17,84	1	0	1,781
MN	-0,576	0,021	25,20	1	0	16,858
MO	-0,156	0,002	19,45	1	0	4,614
ROE	-0,146	0,001	22,46	1	0	1,104
ROA	-0,175	0,011	20,16	1	0	1,361
Tipo (1)	-0,238	0,001	75,61	1	0	1,317
Tipo (2)	-0,234	0,002	68,23	1	0	1,345
Tipo (3)	-0,166	0,002	62,51	1	0	1,409
Tipo (4)	-0,478	0,001	89,27	1	0	1,076
Tamaño (1)	45,25	0,002	53,12	1	0	9823,4
Tamaño (2)	19,38	0,002	58,91	1	0	8516,2
Tamaño (3)	0,110	0,002	69,45	1	0	2,559
Edad (1)	16,29	0,012	74,52	1	0	0,0001
Edad (2)	16,31	0,011	86,32	1	0	0,0008
Edad (3)	1,177	0,010	95,01	1	0	11,561
Constante	-7,445	0,012	25,64	1	0	

Fuente: Elaboración de los autores, con base en la salida de IBM SPSS Modeler 18.2.

Al poner a prueba el modelo en torno a su poder de clasificación, la tabla 5 muestra como la base de entrenamiento posee un nivel de acierto del 98,76%, y en la base de comprobación, un 98,9%. En términos de importancia, la base de validación tiene un acierto del 98,9%, lo cual es importante para este tipo de modelos, dado que se refiere a la nueva población que se tendría para estudio de aprobación de crédito.

TABLA 5. MATRIZ DE CLASIFICACIÓN DE LA REGRESIÓN LOGÍSTICA

Partición	Entrenamiento		Comprobación		Validación	
Correctos	4.554	98,76%	4.770	98,9%	2.330	98,9%
Erróneos	57	1,24%	53	1,1%	26	1,1%
Total	4.611	100%	4.823	100%	2.356	100%

Fuente: Elaboración de los autores, con base en la salida de IBM SPSS Modeler 18.2.

Análisis discriminante

El análisis discriminante es una técnica multivariada, con la cual se logra describir la relación entre dos muestras, y que las diferencias entre ellas se maximicen. A la vez, es una técnica que permite clasificar una nueva observación referente a un grupo de estudio; además, el análisis descriptivo permite encontrar las variables que más inciden en la clasificación de la nueva observación.

Los resultados obtenidos a través del análisis de la minimización de la Lambda de Wilk y la prueba F nos arrojan que las variables que más inciden sobre el incumplimiento de la deuda son el nivel de endeudamiento (NE) y la razón corriente (RC). Asimismo, se obtiene una fuerza de relación de 0,752 (correlación canónica) entre las variables explicativas y el incumplimiento. La tabla 6 muestra los coeficientes de la función discriminante, los cuales contienen 8 de las 11 variables independientes utilizadas en el estudio. En este caso, las variables tamaño, edad y tipo no forman parte de la función.

TABLA 6. COEFICIENTES DE LA FUNCIÓN DISCRIMINANTE ESTIMADA

RC	NE	CE	A	MN	MO	ROE	ROA
-0,578	0,785	0,023	-0,004	0,074	0,106	-0,062	-0,093

Fuente: Elaboración de los autores, con base en la salida de IBM SPSS Modeler 18.2.

En torno a la predicción del modelo obtenido por la técnica del análisis discriminante, se tiene que, para la base de entrenamiento, el acierto es del 77,77%; para la base de comprobación, es del 78,27%; y para la de validación, es del 76,66%. Cabe decir que el estudio de De Llano et al. (2016) indica que una debilidad de esta técnica es su inestabilidad temporal.

TABLA 7. MATRIZ DE CLASIFICACIÓN DEL ANÁLISIS DISCRIMINANTE

Partición	Entrenamiento		Comprobación		Validación	
Correctos	3.586	77,77%	3.775	78,27%	1.806	76,66%
Erróneos	1.025	22,23%	1.048	21,73%	550	23,34%
Total	4.611	100%	4.823	100%	2.356	100%

Fuente: Elaboración de los autores, con base en la salida de IBM SPSS Modeler 18.2.

Red neuronal

Esta técnica se basa en utilizar unos parámetros, que en este caso son suministrados por el investigador, a través de los cuales se alimenta y conforma un modelo que permite predecir una nueva observación que haga parte del suceso en estudio. La ilustración 3 muestra una red neuronal de 7 capas, la cual utiliza las 11 variables independientes planteadas en el estudio, y en la que se evidencian las distintas conexiones que originan los predictores seleccionados.

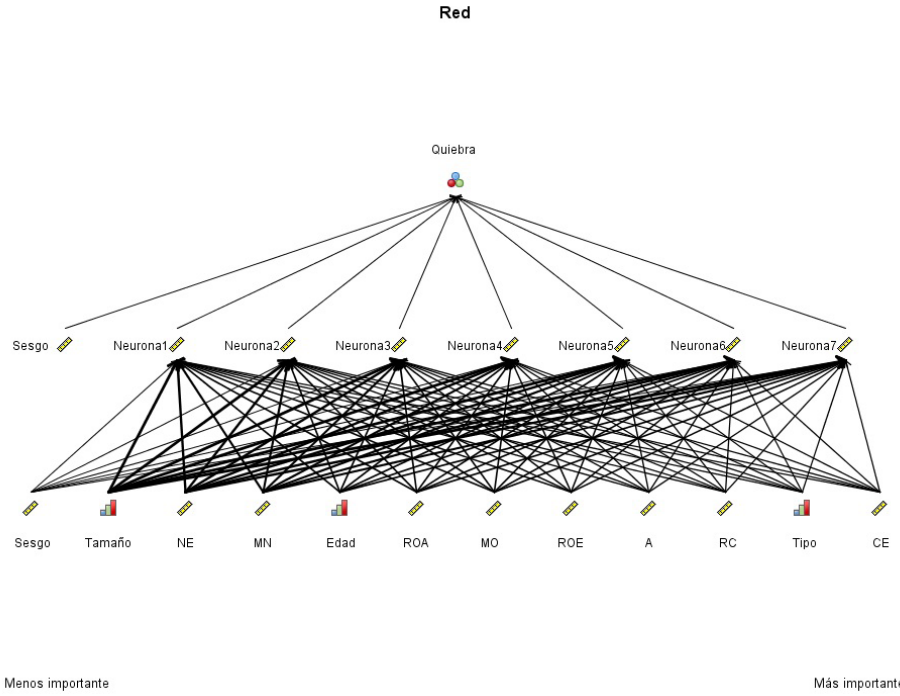

Modelo de red neuronal, salida IBM SPSS Modeler 18.2.

En la red neuronal encontrada se evidenció que las variables más significativas, en términos de importancia en la predicción, fueron tamaño (22%), nivel de endeudamiento (18%) y margen neto (16%); les sigue edad (10%), ROA (10%), MO (9%) y ROE (8%), y un tercer grupo, conformado por las variables apalancamiento (3%), razón corriente (2%) y tipo (2%). En torno a su nivel de predicción la base de entrenamiento arroja un nivel de acierto del 98,72%; la de comprobación, un 98,67%; y la de validación, un 98,77% (tabla 8).

TABLA 8. MATRIZ DE CLASIFICACIÓN DE LA RED NEURONAL

Partición	Entrenamiento		Comprobación		Validación	
Correctos	4.552	98,72%	4.759	98,67%	2.327	98,77%
Erróneos	59	1,28%	64	1,33%	29	1,23%
Total	4.611	100%	4.823	100%	2.356	100%

Fuente: Elaboración de los autores, con base en la salida de IBM SPSS Modeler 18.2.

Comparación de modelos

Tomando como referencia los resultados consolidados de la tabla 9, los modelos obtenidos a través del árbol de decisión, regresión logística y red neuronal alcanzaron en las tres bases (entrenamiento, comprobación y validación) una precisión por encima del 98%. Por otra parte, aunque el modelo encontrado a través de la técnica de análisis discriminante resulta siendo bueno, posee una precisión por debajo del 79% en las tres bases (entrenamiento, comprobación y validación).

En relación con la utilización de las variables explicativas en los modelos, mientras que la regresión logística y la red neuronal utilizan las 11 variables planteadas en la investigación, en el caso del análisis discriminante solo toma las 8 variables financieras, descartando todas las variables no financieras. En el caso del modelo arrojado por el árbol de decisión, este se basa en tres variables financieras (razón corriente, nivel de endeudamiento y margen operativo) y en el tamaño. Por otra parte, la prueba de Kolmogórov-Smirnov (KS), en la cual se plantea una hipótesis nula ($H_{0)}$ que establece que la distribución empírica es similar a la teórica (es decir, hay un buen ajuste), todos los modelos muestran un buen nivel de precisión con un p-valor mayor al 5% (tabla 9).

TABLA 9. COMPARACIÓN DE MODELOS

Tópico	Árbol decisión	Regresión logística	Análisis discriminante	Red neuronal
KS	18,42	18,64	16,31	18,61
Precisión (%) entrenamiento	98,42%	98,76%	77,77%	98,72%
Precisión (%) comprobación	98,30%	98,90%	78,27%	98,67%
Precisión (%) validación	98,30%	98,91%	76,66%	98,77%
Tasa malos global	1,58%	1,47%	22,23%	1,28%
Aceptación (%)	81,78%	80,07%	76,64%	80,05%
Negación (%)	18,22%	19,03%	23,36%	19,05%
Variables	RC	RC	RC	RC
	NE	NE	NE	NE
	-	CE	CE	CE
	-	A	A	A
	-	MN	MN	MN
	MO	MO	MO	MO
	-	ROE	ROE	ROE
	-	ROA	ROA	ROA
	-	Tipo	-	Tipo
	Tamaño	Tamaño	-	Tamaño
	-	Edad	-	Edad

Fuente: Elaboración de los autores, con base en la salida de IBM SPSS Modeler 18.2.

En torno a la hipótesis 1 planteada por los investigadores, los modelos encontrados aportan suficiente evidencia que indica que la información financiera es útil para clasificar y pronosticar el incumplimiento en los pagos de un deudor. En cuanto a la hipótesis 2, comparar los resultados de los modelos (árbol de decisión, regresión logística y red neuronal) que utilizaron las variables financieras y las no financieras, frente al modelo de análisis discriminante que solo utiliza variables financieras, se puede ver que el nivel de precisión de este último es inferior frente a los primeros, con lo cual se puede aceptar la hipótesis 2. Por último, la hipótesis 3 es respaldada con lo analizado anteriormente, de tal manera que los modelos heurísticos arrojan mayor precisión que los modelos multivariantes. En términos generales, de todos los modelos, se prefiere el árbol de decisión, por su simplicidad y

presentación, y porque no requiere un gran número de variables explicativas para conseguir un similar porcentaje de precisión en la clasificación y el pronóstico.

Conclusiones

La principal contribución ha sido la comparación entre las cuatro técnicas de clasificación y predicción desarrolladas en el trabajo, las cuales arrojan evidencias que permiten aceptar el poder de precisión de los modelos encontrados, todos ellos por encima del 98% (a excepción del análisis discriminante, con un 76%). Adicionalmente, los modelos ratifican el poder de predicción de las variables financieras, dada su participación en todos los modelos encontrados a través de las cuatro técnicas utilizadas. En relación con las variables no financieras, solo en el análisis discriminante no fueron utilizadas; sin embargo, de las tres variables propuestas, el tamaño es la que más prevalece en los modelos de árbol de decisión, regresión logística y red neuronal.

De los tres modelos con mayor precisión (árbol de decisión, regresión logística y red neuronal) se recomienda el árbol de decisión, debido a su simplicidad y a su presentación, y a que es el modelo que menos variables utiliza al momento de clasificar y pronosticar un cliente. Esto se considera una gran ventaja a la hora de mirar la escasez de variables de las que disponen las instituciones financieras, debido a la restricción de información que se viene presentando a causa de las leyes de protección al consumidor.

Finalmente, el presente trabajo concluye que los signos encontrados en los distintos modelos concuerdan con la teoría financiera; sin embargo, en el caso del modelo de red neuronal, su complejidad y la ausencia de claridad en su funcionamiento interno no permiten hacer un análisis más profundo de las variables.

Bibliografía

Acosta, E., Fernández, F., & Ganga, H. (2019). Predicting corporate financial failure using macroeconomic variables and accounting data. *Computational Economics*, *53*(1), 227-257. https://doi.org/10.1007/s10614-017-9737-x

Ala'raj, M., & Abbod, M. (2016). Classifiers consensus system approach for credit scoring. *Knowledge-Based Systems*, *104*, 89-105. https://doi.org/10.1016/j.knosys.2016.04.013

Assef, F., & Steiner, M. (2020). Ten-year evolution on credit risk research: A systematic literature review approach and discussion. *Ingenieria e Investigacion*, *40*(2), 1-21. https://doi.org/10.15446/ing.investig.v40n2.78649

Bärtl, M., & Krummaker, S. (2020). Prediction of claims in export credit finance: a comparison of four machine learning techniques. *Risks*, *8*(1), Article 22. https://doi.org/10.3390/risks8010022

Chopra, A., & Bhilare, P. (2018). Application of Ensemble Models in Credit Scoring Models. *Business Perspectives and Research*, *6*(2), 129-141. https://doi.org/10.1177/2278533718765531

De Llano, P., Piñeiro, C., & Rodriguez, M. (2016). Business failure prediction. A contribution to the synthesis of a theory, through comparative analysis of different prediction techniques. *Revista de Estudios de Economía*, *43*(2), 163-198.

Do Prado, J., Carvalho, F., Benedicto, G., & Lima, A. (2019). Análisis del riesgo de crédito que enfrentan las empresas de capital abierto en Brasil: un enfoque utilizando análisis discriminante regresión logística y redes neuronales artificiales. *Estudios Gerenciales*, *35*(153), 347-360. https://doi.org/10.18046/j.estger.2019.153.3151

Dwivedi, P., & Tripathi, S. (2019). A fuzzy knowledge based system for financial credit classification. *International Journal of Recent Technology and Engineering*, *8*(3), 7664-7673. https://doi.org/10.35940/ijrte.C6234.098319

Gepp, A., Kumar, K., & Bhattacharya, S. (2010). Business Failure Prediction using Decision Trees. *Journal of Forecasting*, *29*(6), 536-555. https://doi.org/10.1002/for.1153

Golbayani, P., Florescu, I., & Chatterjee, R. (2020). A comparative study of forecasting corporate credit ratings using neural networks, support vector machines, and decision trees. *North American Journal of Economics and Finance*, *54*, Article 101251. https://doi.org/10.1016/j.najef.2020.101251

Grundke, P., Pliszka, K., & Tuchscherer, M. (2019). Model and estimation risk in credit risk stress tests. *Review of Quantitative Finance and Accounting*. https://doi.org/10.1007/s11156-019-00840-5

Halteh, K., Kumar, K., & Gepp, A. (2018). Using cutting-edge tree-based stochastic models to predict credit risk. *Risks*, *6*(2), Article 55. https://doi.org/10.3390/risks6020055

Hesarzadeh, R. (2019). Son roles individuales y colectivos de los informes financieros medidas de calidad lo mismo? Evidencia en el contexto de la incertidumbre de la información. *Revista española de financiación y contabilidad*, *48*(2), 160-202. https://doi.org/10.1080/02102412.2018.1469858

Jabeur, S., Sadaaoui, A., Sghaier, A., & Aloui, R. (2020). Machine learning models and cost-sensitive decision trees for bond rating prediction. *Journal of the Operational Research Society*, *71*(8), 1161-1179. https://doi.org/10.1080/01605682.2019.1581405

Li, J., Mirza, N., Rahat, B., & Xiong, D. (2020). Machine learning and credit ratings prediction in the age of fourth industrial revolution. *Technological Forecasting and Social Change*, *161*, Article 120309. https://doi.org/10.1016/j.techfore.2020.120309

Syed Nor, S., Ismail, S., & Yap, B. (2019). Personal bankruptcy prediction using decision tree model. *Journal of Economics, Finance and Administrative Science*, *24*(47), 157-170. https://doi.org/10.1108/JEFAS-08-2018-0076

Trivedi, S. (2020). A study on credit scoring modeling with different feature selection and machine learning approaches. *Technology in Society*, *63*, Article 101413. https://doi.org/10.1016/j.techsoc.2020.101413

Wang, G., Ma, J., Huang, L., & Xu, K. (2012). Two credit scoring models based on dual strategy ensemble trees. *Knowledge-Based Systems*, *26*, 61-68. https://doi.org/10.1016/j.knosys.2011.06.020

Xia, Y., He, L., Li, Y., Fu, Y., & Xu, Y. (2021). A dynamic credit scoring model based on survival gradient boosting decision tree approach. *Technological and Economic Development of Economy*, *27*(1), 96-119. https://doi.org/10.3846/tede.2020.13997