



Sensibilidad de las calificaciones crediticias a elasticidades de las razones financieras respecto a variables macroeconómicas: un modelo de árboles de decisión clasificadores para las empresas mexicanas

Credit rating sensitivity to elasticities of financial ratios respect to macroeconomic variables: A classifier decision trees model for mexican firms

Ana Cecilia Parada Rojas, Jorge Omar Razo De Anda*, Salvador Cruz Aké

Escuela Superior de Economía del Instituto Politécnico Nacional, México

Recibido el 21 de septiembre de 2019; aceptado el 30 de noviembre de 2020

Disponible en Internet el: 13 de enero de 2021

Resumen

Los factores que influyen en un cambio de calificación crediticia se desconocen porque el proceso de asignación depende de empresas privadas, por lo que identificar estos factores en combinación con determinadas situaciones macroeconómicas es fundamental para gestionar el riesgo crediticio, más allá del proceso privado de asignación de calificaciones. El objetivo de este artículo es determinar un conjunto de reglas que permitan a la gerencia de la empresa anticipar el cambio en la calificación crediticia de una empresa mexicana, considerando los niveles de elasticidad de sus razones financieras a

*Autor para correspondencia

Correo electrónico: jorgerazodeanda@gmail.com (J.O. Razo De Anda).

La revisión por pares es responsabilidad de la Universidad Nacional Autónoma de México.

<http://dx.doi.org/10.22201/fca.24488410e.2021.2708>

0186- 1042/© 2019 Universidad Nacional Autónoma de México, Facultad de Contaduría y Administración. Este es un artículo

Open Access bajo la licencia CC BY-NC-SA (<https://creativecommons.org/licenses/by-nc-sa/4.0/>)

variables macroeconómicas desde un enfoque de minería de datos, a través de un proceso iterativo de ajuste de regresión logística y un modelo de árbol de decisión clasificador utilizando datos públicos.

Código JEL: C63, G32, C53

Palabras clave: Riesgo crédito; Árboles de regresión y clasificación; Minería de datos

Abstract

The factors that influence a change in credit rating are unknown because the allocation process depends on private companies, so identifying these factors in combination with certain macroeconomic situations is essential to manage the credit risk, beyond the private process of assigning grades. The objective of this paper is to determine a set of rules that allow to firm's management to anticipate the change in the credit rating of a Mexican firm, considering the levels of elasticity of its financial ratios to macroeconomic variables from a data mining approach, through an iterative logit regression fitting process and a classification decision tree model using public data.

JEL Code: C63, G32, C53

Keywords: Credit risk; Classification and regression trees; Data mining

Introducción

Actualmente, las calificaciones crediticias son emitidas por agencias calificadoras de riesgo que evalúan la capacidad de pago del emisor, mitigan el riesgo crediticio y reducen la asimetría de información entre el deudor y el prestamista. Las calificaciones crediticias son puntos de referencia no sólo para quienes emiten deuda, sino que también son señales de mercado sobre la estabilidad financiera de las empresas. Como se muestra en el trabajo de Wojewodzki, Poon, y Shen (2018) y de Kisgen (2019), los ajustes de las calificaciones crediticias afectan el precio de las acciones y la estructura de capital.

Debido al entorno cambiante, la capacidad de una empresa para cumplir con sus obligaciones no es estática, lo que lleva a un proceso sistemático de evaluación crediticia. Desafortunadamente, la metodología del proceso de calificación no es de dominio público, por lo que es imposible identificar y medir las variables utilizadas para ratificar o cambiar la calificación de una empresa.

Para resolver este problema de información, se propone una metodología que permite identificar los factores que influyen en el cambio de calificación crediticia a partir de información de acceso público, como las razones financieras relacionadas y datos macroeconómicos, la cual incluye un proceso de modelado iterativo de regresiones logísticas y un árbol de clasificación. Por lo tanto, esta metodología puede clasificarse como una metodología de calificación crediticia fundamental.

Uno de los primeros modelos fundamentales de calificación crediticia es el propuesto por Beaver (1966). Él propuso el uso de razones financieras de liquidez para predecir la probabilidad de quiebra. Un enfoque similar, pero más reciente, es el trabajo de Le y Viviani (2018) que utiliza técnicas de aprendizaje automático sobre razones financieras para predecir cambios en la calificación crediticia. También vale la pena mencionar a Acosta-González, Fernández-Rodríguez, y Ganga (2019) que también incluyen datos macroeconómicos y razones financieras con el mismo propósito.

Desde el enfoque fundamental se encuentra el trabajo seminal de Altman E. I. (1968) que utiliza análisis discriminante multivariante para predecir la quiebra. Ejemplos de esfuerzos más recientes en esa dirección se aprecian en el trabajo de Almamy, Aston y Ngwa (2016) en el que se utiliza la Z de Altman y el índice de flujo de efectivo para predecir fallas corporativas, y en el trabajo de Kliestik, Vrbka y Rowland (2018) quienes presentan un análisis discriminante basado en razones financieras para revelar un desarrollo poco saludable de la empresa¹.

Probablemente, el modelo fundamental más común para abordar el tema de dificultades financieras es el de Merton (1974), que es un modelo de referencia incluso al día de hoy, como se muestra en los trabajos de Anuwar y Jaffar (2017) y Lee y Yu (2020); ambos artículos utilizan este modelo como base.

Con la evolución del poder de cómputo, los métodos econométricos se vuelven progresivamente más críticos en la evaluación del riesgo crediticio. Ejemplos de esta tendencia son obras como las de Schmid (2012) o Zamore, Djan, K., y Hobdari (2018). Los modelos econométricos han tomado dos sendas principales: modelos cualitativos como Logit o Probit (Nehrebecka, 2018) y modelos de datos panel (Mpofu y Nikolaidou, 2018).

Las variables más utilizadas en el análisis de riesgo crediticio son las razones financieras según Woo, Kwon y Yuen (2020), Mishra y Bansal (2019) o Khemakhem y Boujelbene (2018) y ciertas variables macroeconómicas como en Dos Reis y Smith (2018) o Hassani y Zhao (2015). En el enfoque fundamental de la literatura sobre evaluación del riesgo crediticio, las variables macroeconómicas tienen una importante influencia en la salud de la empresa, pero lo hacen de manera diferente dependiendo de las características de la misma, como la situación y estructura financiera y la industria.

En este trabajo se propone considerar la elasticidad de razones financieras fundamentales con respecto a variables macroeconómicas como el tipo de cambio *spot*, el Producto Interno Bruto, el empleo, la tasa de interés interbancaria y el riesgo país, a partir de una combinación de búsqueda econométrico-computacional de variables significativas. Específicamente, se utiliza un algoritmo de ajuste Logit, como en Ramlall (2018), y árboles de decisión, como

¹ El uso de razones financieras como: cociente de activos a pasivos corrientes, cociente de ingresos netos a activos totales, cociente de pasivos no corrientes y pasivos corrientes a activos totales, cociente de efectivo y equivalentes de efectivo a activos totales y rendimiento del capital.

en Bach, Zoroja, Jaković, y Šarlija (2017) para establecer las interacciones jerárquicas de los factores de riesgo que induzcan cambios en la calificación crediticia.

El objetivo principal de este trabajo es identificar un conjunto de reglas que permitan prever cambios en la calificación crediticia de un conjunto de empresas mexicanas. El argumento principal del artículo es: si las razones financieras son sensibles a las variables macroeconómicas, entonces una combinación de las elasticidades de las razones financieras² con respecto a las variables macroeconómicas actúa como predictor de cambios en la calificación crediticia.

Para identificar la combinación adecuada de elasticidades (de las 12 razones financieras relacionadas con las 10 variables macroeconómicas propuestas), se utiliza un algoritmo de ajuste logístico que selecciona de las 120 elasticidades calculadas las que son estadísticamente significativas. Una vez finalizado el proceso de selección, se utiliza un árbol de decisiones clasificador para encontrar el conjunto de reglas que guían el proceso de calificación crediticia.

Es importante destacar que este método clasifica correctamente el 90.6% de los datos y, los resultados muestran que la industria a la que pertenecen las empresas es el primer y más importante criterio de agrupación, seguido de las elasticidades capital de trabajo respecto al PIB, solvencia respecto a la morosidad del consumidor, cociente de endeudamiento respecto al riesgo país y rotación de inventarios respecto al desempeño del mercado financiero.

En la sección uno del documento, se hace una revisión de la literatura académica sobre las razones financieras como desencadenantes de cambios en la calificación crediticia, además de revisar las interacciones macroeconómicas más comunes con respecto a las calificaciones crediticias, la solvencia y, en general, la capacidad de la empresa para cumplir con sus compromisos financieros. En la sección dos, se presenta la metodología propuesta que incluye el algoritmo de ajuste *Logit Delete Worse* utilizado para seleccionar las elasticidades estadísticamente significativas en los cambios de calificación crediticia; las cuales son utilizadas como insumos para el modelo de árbol clasificador que proporciona el conjunto de reglas que permiten prever los cambios en la calificación. En la sección tres, se presenta el análisis de resultados del modelo. Finalmente, se presentan las conclusiones y la agenda de investigación futura.

Revisión de la literatura

Según el Comité de Basilea, BCBS³, las regulaciones financieras se han fortalecido debido a los recientes incumplimientos. Una regulación destacable es la que requiere que al menos

² Las razones financieras utilizadas se describen en las siguientes secciones

³ Comité de Supervisión Bancaria de Basilea (BCBS), 2004. Basilea II: Convergencia internacional de medición de capital y estándares de capital: un marco revisado. Informe 107, Banco de Pagos Internacionales, Basilea.

dos agencias calificadoras deban evaluar la capacidad de pago de aquellas firmas dispuestas a vender instrumentos de deuda, para más detalles ver (Hofbauer, Klimontowicz y Nocoñ, 2016) y (Sbárcea, 2014).

Como se señaló en Bonsall y Miller (2017) y en Figlioli, Moreira Antonio y Guasti Lima (2019), las calificaciones crediticias son señales de mercado capaces de cambiar el costo de la deuda o el precio de las acciones y, por esa razón, son importantes. Desafortunadamente, no son accesibles para las pequeñas empresas porque solo tres agencias concentran su oferta (S&P, Moody's y Fitch), lo que las encarece.

Por otro lado, las agencias de calificación crediticia fueron objeto de escrutinio académico y del mercado después de la crisis financiera de 2007 (DeHaan, 2017) y (Hassani y Zhao, 2015). Por esta razón, los académicos desarrollan modelos para la evaluación del riesgo crediticio. Ejemplos de esos esfuerzos son Duffie y Singleton (2012) además de un enfoque en tiempo continuo con cadenas de Markov como en Koopman y Lucas (2008) y Dos Reis y Smith (2018).

Como parte del esfuerzo académico, el enfoque de modelado econométrico de la probabilidad de incumplimiento y la evaluación del riesgo crediticio utiliza modelos de variables dicotómicas o categóricas. Ejemplos de este enfoque son Hernandez-Tinoco y Wilson (2013) y Hernandez Tinoco, Holmes y Wilson (2018).

El enfoque econométrico también tiene la rama del análisis discriminante (Altman E. I., 2013), (Zmijewski, 1984) o (Peres y Antão, 2017). La principal diferencia entre esos documentos son las variables explicativas que utilizan (razones financieras o características de la empresa), pero no existe un enfoque dominante para la selección de variables (Husein y Pambekti, 2015), (Mihalovic, 2016) o (Alifiaha y Tahir, 2018).

La variedad de enfoques y trabajos que explican los eventos crediticios (incumplimientos y cambios de calificación) se puede atribuir principalmente a que el criterio de selección de variables no es homogéneo debido a las fuentes de información: internas o externas a la empresa; Korol y Korodi (2010) muestran que no hay un solo factor determinante de la insolvencia.

En la literatura académica, existe una división teórica entre causas internas y externas. Entre las causas internas se encuentran las ineficiencias en la asignación de recursos, la estructura de capital y la administración de la empresa, véase (Zhang, Bessler, y Leatham, 2013). De forma similar, Altman E. I. (2013) y Brusov, Filatova, Orekhova y Eskindarov (2018) señalan a la cobertura de intereses y otros índices de servicio de la deuda y a los cambios en el costo de capital promedio ponderado, WACC, como razones principales para marcar un cambio de calificación crediticia.

Por otro lado, los autores como Korol y Korodi (2010) o Hernandez-Tinoco y Wilson (2013) destacan las fuentes externas argumentando que los estados financieros no contienen toda la información relevante de la empresa. Estos autores incluyen variables macroeconó-

micas y de mercado para complementarlas. Liou y Smith (2006), Alifiaha y Tahir (2018) y Hernandez Tinoco, Holmes y Wilson (2018) también incluyen información de mercado para mejorar sus predicciones o análisis de eventos crediticios.

La falta de consenso en los determinantes de los eventos crediticios puede ocurrir debido a la no normalidad en las razones financieras (Alifiaha y Tahir, 2018), (Linares-Mustarós, Coenders y Vives-Mestres, 2018) o por cuestiones de colinealidad y valores extremos. Otros autores como Fontaine Rezende, *et al.* (2017) optan por un tratamiento previo para los datos como: descartar variables mediante pruebas de colinealidad, regresión y correlación o censura de valores extremos.

Autores como West (2000); Li, *et. al* (2017) y Tian, Yong y Luo (2018) exploran el uso de nuevas técnicas como el aprendizaje automático y la minería de datos para asignar créditos al consumidor, evaluación de riesgos o predicción de quiebras. Es importante enfatizar que estas técnicas no hacen suposiciones sobre las distribuciones, varianza o dependencia de las variables porque eliminan redundancias a través de iteraciones o clasificación.

Entre las técnicas de aprendizaje automático e inteligencia artificial más efectivas y populares se encuentran las redes artificiales neuronales, RNA. Schmidhuber (2015) y Angelini, di Tollo y Roli (2008) propusieron su uso en el sector financiero evaluando el riesgo crediticio utilizando razones financieras.

Cuando el número de variables es engorroso o las complejidades del problema no son manejables con las metodologías tradicionales, como los problemas de calificación crediticia, las técnicas como *Support Vector Machine*, MVS, son una opción razonable para lograr predicciones. Lee Y. (2007), Wang (2017) y Prodan-Palade (2017) obtuvieron la misma conclusión al comparar herramientas de aprendizaje supervisado en el mismo problema de evaluación del riesgo crediticio.

En este artículo, utilizamos el método de árboles de clasificación y regresión, CART. Esta metodología ofrece más información que otras técnicas de aprendizaje automático, incluidas las relaciones entre las variables explicativas, aunque aceptan un error más significativo que MVS o RNA (Rokach y Maimon, 2014).

Ruxanda, Zamfir y Muraru (2018) encontraron que las razones financieras utilizadas como insumos para la metodología CART muestran un mejor desempeño en períodos de dificultades financieras que el análisis discriminante MVS o técnicas econométricas.

Por otra parte, Barboza, Kimura y Altman (2017) comparan las técnicas de *MVS*, *Random Forest*, *Bagging* y *Boosting* con los modelos econométricos tradicionales y RNA's que predicen las quiebras con un año de anticipación; los autores obtuvieron un aumento del 10% en el poder predictivo. Estos resultados fueron similares a los de Wang (2017) y Wagle, Yang y Benslimane (2017). Para una revisión más detallada de los algoritmos de aprendizaje supervisado sobre riesgo crediticio, consulte (Devi y Radhika, 2018).

Es importante enfatizar que la metodología CART nos permite establecer una jerarquía y un conjunto de reglas para clasificar, como en el proceso de calificación, lo cual es nuestro objetivo. Barboza, Kimura y Altman (2017) mostraron que la metodología CART mejorada mediante técnicas de *bagging* o *bootstrapping* puede lograr una mayor precisión en los resultados. La mayoría de los artículos que utilizan estas técnicas consideran variables proxy para medir el riesgo crédito (swaps), sin embargo, una de las limitaciones de nuestra investigación es que consideramos cambios de calificación asignada directamente por las calificadoras, y dado que estos cambios son esporádicos la cantidad de datos es relativamente pequeña como para aplicar este tipo de técnicas.

Metodología

La metodología propuesta consta de tres etapas. La primera consiste en calcular elasticidades entre razones financieras y factores macroeconómicos (ambos son información pública). Estos datos nos brindan una visión dinámica de la evolución de las empresas junto con el entorno macroeconómico. En la segunda etapa se descartan las variables no relacionadas o redundantes mediante un algoritmo DW de ajuste de regresión Logística⁴. Finalmente, se construye un árbol de clasificación de los eventos crediticios (cambios de calificación) en función de las elasticidades estadísticamente significativas.

Descripción de los datos

En este trabajo se utiliza información pública macroeconómica de la economía mexicana⁵ y razones financieras trimestrales calculadas con información de Economía para el período 1998-2018. Suponemos que las calificadoras de riesgo tienen acceso a la misma información que la publicada⁶, por lo que la metodología captaría la misma dinámica.

En primer lugar, desde el punto de vista de factores internos que pueden generar cambios en la calificación crediticia, se presenta en la tabla 1 la información relacionada con las razones financieras, su cálculo y descripción, además de referencias de trabajos que han utilizado cada una de las razones propuestas en este artículo para describir la situación financiera de las empresas.

⁴ Disponible a petición por correo electrónico

⁵ Recopilada de INEGI, la entidad pública mexicana responsable de la construcción y publicación de Estadísticas Nacionales en México <https://www.inegi.org.mx/sistemas/bie/>

⁶ El trabajo utiliza información de los estados financieros publicados por las mismas empresas, por lo que cualquier error u omisión (consiente o no) que las empresas reporten, con el objetivo de evitar bajas de calificación o para mejorar su calificación (contabilidad creativa), queda bajo la responsabilidad de las empresas

Tabla 1

Descripción de razones financieras

Razones de liquidez			
Razón	Nombre	Descripción	Referencias
Cociente de liquidez	LIQ	Activos corrientes/Pasivos corrientes	(Zmijewski, 1984), (Altman E. I., 2013), (Alifiaha y Tahir, 2018) (Ruxanda, Zamfir, y Muraru, 2018)
Prueba ácida	PBACID	(Activos corrientes - Inventarios) / Pasivos corrientes	(Fontaine Rezende, da Silva Montezano, Nascimento de Oliveira, y de Jesus Lameira, 2017)
Capital de trabajo a Activos	RCTA	(Activos corrientes - Pasivos corrientes) / (Activos Totales)	(Alifiaha y Tahir, 2018), (Altman E. I., 2013), (Fontaine Rezende et al. 2017)
Razones de actividad			
Razón	Nombre	Descripción	Referencias
Rotación de inventarios	RINVT	Costo de ventas /Inventario	(Bendig, Strese y Brettel, 2017), (Elking et al., 2017), (Chuang, Oliva y Heim, 2019)
Rotación de capital de trabajo	RCT	Ventas netas/ (Activos corrientes - Pasivos corrientes)	(Bendig, Strese y Brettel, 2017), (Elking et al., 2017), (Chuang, Oliva y Heim, 2019)
Rotación de activos totales	RAT	Ventas netas/Activos totales	(Fontaine Rezende et al., 2017), (Ruxanda, Zamfir y Muraru, 2018)
Razones de apalancamiento financiero			
Razón	Nombre	Descripción	Referencias
Cociente de deuda	RDT	Pasivos totales/Activos totales	(Hernandez-Tinoco y Wilson, 2013), (Alifiaha y Tahir, 2018), (Hernandez Tinoco, Holmes y Wilson, 2018), (Ruxanda, Zamfir y Muraru, 2018), (Kemper, 2020)
Cociente deuda a capital	RDTCC	Pasivos totales/Capital total	(Ruxanda, Zamfir y Muraru, 2018)
Razones de cobertura			
Razón	Nombre	Descripción	Referencias
Cociente de cobertura de interés	RINTD	EBIT/Gastos en interés	(Hernandez-Tinoco y Wilson, 2013), (Hernandez Tinoco, Holmes y Wilson, 2018), (Kemper, 2020)

Razones de rentabilidad			
Razón	Nombre	Descripción	Referencias
Margen de utilidad neta	MUT	Utilidad neta/Ingreso operativo total	(Altman E. I., 2013)
Retorno en los activos	ROA	Utilidad neta / Activos totales	(Altman E. I., 2013), (Alifiaha y Tahir, 2018), (Ruxanda, Zamfir y Muraru, 2018)
Retorno en el capital	ROE	Utilidad neta / Capital	(Ruxanda, Zamfir y Muraru, 2018)

Fuente: Elaboración propia

En términos de factores externos, Hussain *et al.* (2005) identifican que el Producto Interno Bruto tiene poder predictivo para la estimación de estrés financiero. En este contexto, los trabajos de Zhang, Bessler, y Leatham (2013), Hernandez-Tinoco y Wilson (2013), Hernández-Tinoco, Holmes, y Wilson (2018) y Rezende et al. (2017) coinciden con el anterior, sin embargo, también incorporan variables referentes a las tasas de interés, índices accionarios e inflacionarios.

Entre los artículos que relacionan razones financieras de deuda, actividad económica y actividad de mercado con la calidad de los créditos, se encuentran los trabajos de Keenan y Sobehart (1999), y Duffie y Singleton (2012) que muestran una relación negativa con respecto a la tasa de morosidad y el crecimiento del PIB en Estados Unidos hasta 1983; en el mismo sentido Koopman *et al.* (2012) incluyen el efecto de mercado a través de componentes principales y Tang, D. Y. y Yan, H. (2010) utilizan los diferenciales de los *Credit Default Swap (CDS)* como una variable aproximada de la morosidad en el mercado.

De la revisión anterior, se identifica un consenso en la literatura con respecto a las siguientes variables: Indicador de actividad económica, Indicador del mercado de valores, Tasas de interés de referencia, Indicador inflacionario y el Índice de morosidad⁷. A fin de incorporar el efecto de estas, en la tabla 2 se presenta la descripción, fuente y periodicidad de las variables utilizadas para el caso mexicano.

⁷ Los índices de morosidad son contruidos como la razón de la cartera vencida sobre la cartera total en créditos al consumo e hipotecarios respectivamente.

Tabla 2

Descripción de las variables macroeconómicas

Variable	Descripción	Fuente
PIB	Producto Interno Bruto (Millones de pesos mexicanos 2008)	(Instituto Nacional de Estadística y Geografía, INEGI, 2020)
INPC	Índice Nacional de Precios al Consumidor	(Instituto Nacional de Estadística y Geografía, INEGI, 2020)
TC	Tipo de cambio, fin de trimestre (Peso mexicano por dólar US)	(Banco de México, BANXICO, 2020)
TIIE	Tasa de interés interbancaria, 28 días	(Banco de México, BANXICO, 2020)
PIBI	Indicador Económico de actividades secundarias	(Instituto Nacional de Estadística y Geografía, INEGI, 2020)
PIBS	Indicador Económico de actividades terciarias	(Instituto Nacional de Estadística y Geografía, INEGI, 2020)
MC	Índice de morosidad en los bancos comerciales, consumo	(Banco de México, BANXICO, 2020)
MV	Índice de morosidad en los bancos comerciales, vivienda	(Banco de México, BANXICO, 2020)
IPC	Índice de Precios y Cotizaciones, mercado mexicano, BMV	INVESTING
RP	Diferencial de tasas CETES (28 días) y US T-Bills	(Banco de México, BANXICO, 2020), (Federal Reserve Bank of Saint Louis, 2020)

Fuente: Elaboración propia. Datos trimestrales, desde 1998 a 2018.

Se utilizan las calificaciones corporativas de largo plazo publicadas por *Fitch Ratings* y *Standard & Poors*. Para homogeneizarlas se utiliza la tabla de correspondencia de calificaciones a largo plazo del Anexo 1-B⁸. Se cuenta con información de 28 empresas emisoras de deuda⁹; 23 calificadas por Fitch, 17 por S&P y 12 por ambas empresas, a lo largo de cada trimestre del período 1998 Q1 – 2018 Q2. Se asigna un valor de “0” a cada período sin cambios en la calificación crediticia y “1” en caso de cambio (mejor o peor calificación). Se calculan 120 elasticidades¹⁰ y se filtran todos los períodos (empresas

⁸ Resolución que modifica las disposiciones generales aplicables a las entidades de crédito:
http://dof.gob.mx/nota_detalle_popup.php?codigo=5186974

⁹ ARCA CONTINENTAL, ALSEA, AMERICA MÓVIL, TV AZTECA, BACHOCO, BIMBO, CEMEX, CHE-DRAUI, CREAL, CULTIBA, ELEKTRA, ELEMENTIA, FEMSA, GRUPO AEROPORTUARIO DEL PACÍFICO, GRUPO CARSO, HERDEZ, ICA, IENOVA, INMUEBLES CARSO, KIMBERLY CLARK, COCA COLA, GENNOMA LAB, LIVERPOOL, MEXICHEM, PEÑOLES, RADIO CENTRO, SORIANA, TELEVISIA

¹⁰ Las elasticidades entre razones financieras y variables macroeconómicas, se obtienen de la división entre las

sin asignación de calificaciones crediticias), de tal forma que se tienen 224 observaciones trimestrales.

Discriminación de elasticidades: algoritmo Delete Worse (DW)

Para descartar las elasticidades no estadísticamente significativas, se utiliza un algoritmo *Delete Worse* (DW) basado en modelos de regresión logística. La metodología DW consiste en descartar iterativamente las elasticidades no estadísticamente significativas hasta que el algoritmo alcance un modelo Logit con todas sus variables significativas a un nivel de confianza 95%. Para evitar el problema de colinealidad y considerando la capacidad explicativa colectiva de las variables en un modelo, ejecutamos el algoritmo con diferentes conjuntos iniciales de variables y mantenemos las variables estadísticamente significativas en cada ejecución. En primera instancia se ejecutan 60 regresiones a partir de conjuntos con pares de elasticidades; posteriormente se realizan 40 regresiones a partir de tripletas y finalmente 24 regresiones a partir de quintetas. De las elasticidades significativas resultantes de estos procesos, se construye una lista de 28 elasticidades diferentes, a partir de lo cual se ejecuta el algoritmo DW que consta de 13 regresiones adicionales; concluyendo con una lista de 15 elasticidades. En la tabla 3 se describe el modelo logístico que utiliza las 15 variables estadísticamente significativas.

Tabla 3

Elasticidades estadísticamente significativas después de ejecutar el algoritmo DW

(Intercepto)***	E_RDT_RP*	E_MUT_TIE*	E_RINVT_IPC*
E_RCTA_PIB*	E_RDTCC_RP*	E_PBACID_MC.	E_RDTCC_IPC*
E_ROA_INPC*	E_RDT_TIE.	E_RINTD_MC*	E_LIQ_MC*
E_ROE_INPC*	E_RINVT_MC.	E_LIQ_IPC*	E_ROA_IPC*

***p < 0.001, **p < 0.01, *p < 0.05 Pseudo R² de Mac Faden = 0.31, 62.94% de precisión de modelo. Fuente: Elaboración propia con (R Core Team, 2020). Se crea el código de variables como: E_razón financiera_variable macro.

tasas de variación de cada una de las 12 razones en combinación con las tasas de cada una de las 10 variables macroeconómicas $\varepsilon_{x_i, y_j} = \frac{v_{x_{it}}}{v_{y_{jt}}} = \frac{(x_{it} - x_{it-1}) / x_{it-1}}{(y_{jt} - y_{jt-1}) / y_{jt-1}} \forall i, j$, siendo la i-esima razón financiera para el trimestre

Tabla 4

Clasificación de empresas en la Bolsa de Valores Mexicana, BMV

<i>Sector</i>	<i>Subsector</i>
1) Energía	Energía
2) Industria	Bienes de capital
	Construcción*
3) Materiales	Transporte
	Materiales*
4) Bienes de consumo frecuente	Comida, bebidas y tabaco
	Productos personales o domésticos
5) Salud	Venta de productos de consumo frecuente*
	Farmacéutico, biotecnología and ciencias de la salud
6) Servicios de telecomunicaciones	Comunicaciones y medios
	Servicios de telecomunicaciones
8) Bienes no básicos y servicios	Servicios al consumidor
	Ventas al menudeo

Fuente: Elaboración propia con información de la Bolsa Mexicana de Valores

*Sectores identificados como discriminantes del grupo 2 del modelo (ver Tabla 7)

Árboles de decisión: Modelo CART

Los árboles de decisión son modelos flexibles y no paramétricos que capturan las interacciones entre variables condicionando las decisiones. En la literatura, esto se conoce como reglas: construcción de combinaciones de valores de entrada para obtener una salida (Faraway, 2016). En estos modelos, los resultados dependen de las decisiones individuales tomadas en el nodo de cada árbol. Un modelo CART clasifica valores en un conjunto de clases definidas que se basan en características de muestra.

Para evitar que el árbol de clasificación y regresión, CART, sobreajuste el modelo, el árbol debe ser “podado”. El proceso de poda consiste en eliminar los nodos finales que no disminuyen en gran medida el poder explicativo del modelo (error de desviación)¹¹. En nuestro modelo, utilizamos las 15 elasticidades tomadas de los pasos anteriores más dos variables categóricas (sector y subsector de la empresa) de acuerdo con la clasificación de la Bolsa Mexicana de Valores, BMV, las cuales se muestran en la tabla 4, siguiendo los trabajos de Liou y Smith, (2011) y Karkinen y Laitinen, (2015) que mencionan que el sector o industria es un discriminante que pueden afectar las operaciones financieras de una empresa.

¹¹ La desviación se define como: $D = \sum_k D_k = \sum_k -2n_k [n_k^c \ln(n_k^c) + n_k^{NC} \ln(n_k^{NC})]$

Usando la librería “tree” (Ripley, 2019) en R, se encontró un árbol, con 17 nodos finales, que clasifica el 90.6% de las observaciones. Para minimizar el costo de complejidad¹², se utiliza un valor de poda, $\alpha = 7.01$, (correspondiente a la mediana). Como resultado, obtuvimos un árbol de clasificación con 13 nodos (7 finales). En la figura 1 se muestra el árbol de decisión en el que se visualizan las reglas que señalan un cambio o no cambio de calificación.

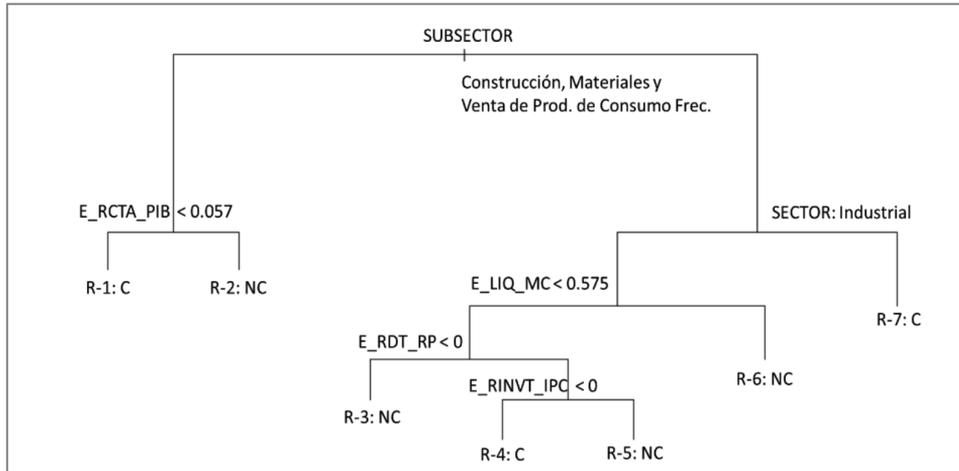


Figura 1. Árbol de clasificación, $\alpha = 7.01$ Impureza del árbol, con un error residual medio, .

Fuente: Elaboración propia usando “tree”, (Ripley, 2019), en *R Project*, (R Core Team, 2020).

Tabla 5

VARIABLES SIGNIFICATIVAS EN EL ÁRBOL PODADO

Variable	Razón financiera	Variable Macroeconómica
E_RCTA_PIB	Capital de trabajo a activos	Producto Interno Bruto
E_LIQ_MC	Razón de liquidez	Índice de incumplimientos en bancos comerciales, consumo
E_RDT_RP		Cociente de Diferencial entre CETES mexicano (28 días de deuda y T-Bills de los EUA)
E_RINVT_IPC		Rotación de inventarios Índice de Precios y Cotizaciones

Fuente: Elaboración propia con el paquete “tree” (Ripley, 2019).

¹² El costo de complejidad esta dado como: $C(T) = D(T) + \alpha \text{Size}(T)$. Donde $D(T)$ es la impureza del árbol de tamaño of size T, $\text{Size}(T)$ es el número de nodos finales y α es el termino de penalización (Ledolter, 2013)

El modelo muestra que el sector económico y el subsector son el principal criterio de clasificación, revelando diferentes sensibilidades sobre los valores macroeconómicos según la industria¹³. El modelo establece una mayor sensibilidad en los sectores de la construcción, materiales (ambos altamente procíclicos) y de productos de consumo frecuente. En la tabla 5 se muestran las elasticidades que conforman las reglas de clasificación del árbol podado.

Para evaluar el árbol de clasificación, se calcula la tasa de clasificación incorrecta, MC (*miss classification*), que mide la capacidad del modelo para generalizar un ejemplo con un nivel de confianza (Rokach y Maimon, 2014). También se realiza una prueba de validación cruzada generando cuatro submuestras aleatorias mutuamente excluidas con una MC promedio de 8.5%.

Tabla 6
 Precisión y exactitud del modelo

	Matriz de confusión			Regla/Excepción			Precisión
	Estimado (C)	Estimado (NC)		C	NC	C	NC
Ejemplos (C)	18	19	C	0.49	0.51	0.9	0.09
Ejemplos (NC)	2	185	NC	0.01	0.99	0.1	0.91

Fuente: Elaboración propia basada en (Rokach y Maimon, 2014).

Como verificación final del modelo, se calcula una matriz de confusión (ver tabla 6) como en Chapra (2012) o Rokach y Maimon (2014). El modelo podado presenta una tasa de precisión de 90.62%.

Análisis de resultados

Una vez que tenemos el árbol de clasificación y la matriz de confusión, presentamos en la Tabla 7 las reglas de cambio de calificación crediticia obtenidas del modelo.

La rama derecha del árbol (Figura 1) representa el segundo grupo de empresas (6) que pertenecen al subsector: Construcción, Materiales o Consumo frecuente, ver tabla 4. En el grupo 1, la probabilidad de que una de estas empresas reciba un cambio de calificación es apenas del 8%, sin embargo, el modelo identifica a la elasticidad entre la razón de capital de trabajo y el crecimiento del Producto Interno Bruto (E_RCTA_PIB) como criterio principal para explicar posibles cambios de calificación

¹³ Principal argumento del modelo CAPM

Tabla 7

Conjunto de reglas del árbol de clasificación

REGLAS						
# Regla	Condición				Probabilidad	
Grupo 1						
1	SI	$E_RCTA_PIB < 0.0564335$		→	C	0.08
2	SI	$E_RCTA_PIB > 0.0564335$		→	NC	0.96
Grupo 2						
3	SI	$E_LIQ_MC < 0.57 \ \& \ E_RDT_RP < 0$		→	NC	0.81
4	SI	$E_LIQ_MC < 0.57 \ \& \ E_RDT_RP > 0 \ \& \ E_RINVT_IPC < 0$		→	C	0.98
5	SI	$E_LIQ_MC < 0.57 \ \& \ E_RDT_RP > 0 \ \& \ E_RINVT_IPC > 0$		→	NC	0.56
6	SI	$E_LIQ_MC > 0.57$		→	NC	0.92
7	SI	Sector = 'Industria' & Subsector='Construcción'		→	C	0.84

Fuente: Elaboración propia basada en el árbol de clasificación.

La interpretación del modelo radica en que el orden de la regla implica jerarquía. Por ejemplo, la Regla 4 establece que, en el grupo 2, si la elasticidad del coeficiente circulante de liquidez con respecto a la morosidad, E_LIQ_MC es menor a 0.57 (paso 1), y la elasticidad del cociente de deuda con respecto al riesgo país, E_RDT_RP , es mayor que cero (paso 2), y además la elasticidad de la rotación de inventario al Índice de Precios y Cotizaciones, E_RINVT_IPC , es menor que cero (paso 3); entonces hay una probabilidad de 0.98 de tener un cambio en la calificación crediticia.

Los resultados del artículo no son sorprendentes, ya que, relacionan la razón capital de trabajo a activos con el PIB, E_RCTA_PIB , como la fuente principal de cambios de calificación crediticia debido a su relación con la capacidad de la empresa a corto plazo para cumplir con sus compromisos financieros sin dinero externo.

El modelo también relaciona la razón corriente con la morosidad, E_LIQ_MC ; lo que significa que, si hay una dificultad generalizada para cobrar deudas, las empresas tendrán menos recursos líquidos y las cuentas por cobrar serán menos valiosas. La siguiente elasticidad significativa es el índice de endeudamiento que se extiende sobre las tasas de interés de corto plazo entre México y Estados Unidos, E_RDT_RP ; esta implica que empresas trans-

nacionales o fuertemente relacionadas con el mercado estadounidense toman decisiones de financiamiento considerando el riesgo país inducido por el diferencial de tasas; el aumento del costo del dinero relativo entre divisas (depreciación del tipo de cambio) demanda directamente más recursos líquidos.

Conclusiones

Los resultados de este trabajo muestran la naturaleza dinámica de la capacidad de una empresa para cumplir con sus compromisos financieros, además de identificar el efecto del entorno macroeconómico en la calificación de la empresa. Así mismo, el conjunto de reglas que se obtienen del árbol de clasificación analiza el proceso cerrado de calificación crediticia.

La estructura del modelo (conjunto de reglas) refleja el conocimiento tradicional y empírico sobre el comportamiento de la capacidad de la empresa para pagar sus deudas relacionadas con el proceso interno de la empresa como rotación de inventarios, liquidez o capital de trabajo a las variables macroeconómicas, tomando en cuenta el sector al que pertenece la empresa.

El modelo CART identifica un conjunto de 7 reglas (descritas en la tabla 7) basadas en la combinación de criterios que representan la situación financiera de una empresa y su sensibilidad al entorno macroeconómico para prever posibles cambios de calificación.

Los cambios de calificación de las empresas mexicanas que pertenecen a los subsectores de materiales y de ventas de productos de consumo frecuente (grupo 2), son susceptibles a razones financieras relacionadas con la liquidez, el endeudamiento y las razones de actividad, así como a su sensibilidad con respecto al riesgo país, la morosidad de los consumidores y el mercado de capitales; mientras que para la mayoría del resto de las empresas de la muestra (grupo 1), la calificación depende de la sensibilidad de la razón de capital de trabajo con respecto a la actividad económica medida por la producción nacional. Es importante mencionar que las elasticidades significativas, indican una relación entre la administración corporativa de la empresa y diferentes tipos de riesgo: mercado, crédito y liquidez.

La metodología propuesta combina lo mejor de las dos ramas del análisis de calificación crediticia: el poder de análisis computacional (paso 1, obtener las 10 variables macroeconómicas * 12 razones financieras * empresas * número de observaciones trimestrales) con el enfoque econométrico tradicional (paso 2, realizado con base en el modelo de regresión logístico, a través del algoritmo de ajuste DW que estima 137 regresiones) con el uso de una técnica de aprendizaje supervisado (paso 3, árbol clasificador y podado).

El modelo CART permite a los gerentes financieros de las empresas identificar factores de riesgo y entornos macroeconómicos que ponen en peligro la capacidad de la empresa para cumplir con sus compromisos financieros; también les permite administrar dichos riesgos

de crédito, de mercado y de liquidez entre los márgenes proporcionados por las respectivas elasticidades de cada empresa.

Entre las futuras investigaciones se encuentran aplicar la metodología a empresas de otros países y comparar si las reglas se mantienen, otra posible línea de investigación es implementar la metodología a otros tipos de riesgo o cambios de calificación, por ejemplo, la emitida por deuda a corto plazo. Esta metodología también se puede mejorar incluyendo técnicas de *bagging* o *bootstrapping* siempre que se incorpore mayor cantidad de observaciones.

Referencias

- Acosta-González, E., Fernández-Rodríguez, F., y 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>
- Alifiaha, M. N., y Tahir, M. S. (2018). Predicting financial distress companies in the manufacturing and non-manufacturing sectors in Malaysia using macroeconomic variables. *Management Science Letters*, 8(6), 593 - 604. <https://doi.org/10.5267/j.msl.2018.4.031>
- Almamy, J., Aston, J., y Ngwa, L. N. (2016). An evaluation of Altman's Z-score using cash flow ratio to predict corporate failure amid the recent financial crisis: Evidence from the UK. *Journal of Corporate Finance*, Vol. 36, February, 36(February), 278-285. <https://doi.org/10.1016/j.jcorpfin.2015.12.009>
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, Vol. 23, No.4, 23(4), 589-609. <https://doi.org/10.2307/2978933>
- Altman, E. I. (2013). Predicting financial distress of companies: revisiting the Z-score and ZETA@models. En A. R. Bell, C. Brooks, y M. Prokopczuk, *In Handbook of research methods and applications in empirical finance* (págs. 428 - 456). Northhampton, MA: Edward Elgar Publishing. <https://doi.org/10.4337/9780857936097.00027>
- Angelini, E., di Tollo, G., y Roli, A. (2008). A neural network approach for credit risk evaluation. *The quarterly review of economics and finance*, 48(4), 733 - 755. <https://doi.org/10.1016/j.qref.2007.04.001>
- Anuwar, M. H., y Jaffar, M. M. (2017). Grading the probabilities of credit default risk for Malaysian listed companies by using the KMV-Merton model. *AIP Conference Proceedings*, 1870(1), 1 - 8. <https://doi.org/10.1063/1.4995857>
- Bach, M. P., Zoroja, J., Jaković, B., y Šarlija, N. (2017). Selection of variables for credit risk data mining models: preliminary research. *40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)* (págs. 1367-1372). Opatija, Croatia: IEEE. <https://doi.org/10.23919/MIPRO.2017.7973635>
- Banco de México, BANXICO. (October de 2020). *Sistema de Información Económica*. Obtenido de Disponible en: <https://www.banxico.org.mx/SieInternet/Consulatdo10/08/2020>
- Barboza, F., Kimura, H., y Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83(October), 405 - 417. <https://doi.org/10.1016/j.eswa.2017.04.006>
- Beaber, W. H. (1966). Financial ratios as predictors of failure. *Journal of accounting research*, 4, 71 -111. <https://doi.org/10.2307/2490171>
- Bendig, D., Strese, S., y Brettel, M. (2017). The link between operational leanness and credit ratings. *Journal of Operations Management*, 52(May), 46 - 55. <https://doi.org/10.1016/j.jom.2016.11.001>
- Bonsall, S. B., y Miller, B. P. (2017). The impact of narrative disclosure readability on bond ratings and the cost of debt. *Review of Accounting Studies*, 22(2), 608 - 643. <https://doi.org/10.1007/s11142-017-9388-0>

- Brusov, P., Filatova, T., Orekhova, N., y Eskindarov, M. (2018). Rating: new approach. En P. Brusov, T. Filatova, N. Orekhova y M. Eskindarov, *Modern Corporate Finance, Investments, Taxation and Ratings* (págs. 441-474). Cham, Switzerland: Springer. <https://doi.org/10.1007/978-3-319-99686-8>
- Chapra, S. C. (2012). *Applied numerical methods with MATLAB for engineers and scientists* (3rd ed.). New York, New York, USA: McGraw-Hill Education.
- Chuang, H. H.□C., Oliva, R., y Heim, G. R. (2019). Examining the link between retailer inventory leanness and operational efficiency: Moderating roles of firm size and demand uncertainty. *Production and Operations Management*, 28(9), 2338-2364. <https://doi.org/10.1111/poms.13055>
- DeHaan, E. (2017). The financial crisis and corporate credit ratings. *The Accounting Review*, 92(4), 161 - 189. <https://doi.org/10.2308/accr-51659>
- Devi, S. S., y Radhika, Y. (2018). A survey on machine learning and statistical techniques in bankruptcy prediction. *International Journal of Machine Learning and Computing*, 8(2), 133 - 139. <https://doi.org/10.18178/ijmlc.2018.8.2.676>
- Dos Reis, G., y Smith, G. (2018). Robust and consistent estimation of generators in credit risk. *Quantitative Finance*, 18(6), 983 - 1001. <https://doi.org/10.1080/14697688.2017.1383627>
- Duffie, D., y Singleton, K. J. (2012). *Credit risk: pricing, measurement, and management*. Princeton, NJ: Princeton University Press. <https://doi.org/10.2143/ast.34.1.504966>
- Elking, I., Paraskevas, J.□P., Grimm, C., Corsi, T., y Steven, A. (2017). Financial dependence, lean inventory strategy, and firm performance. *Journal of Supply Chain Management*, 53(2), 22 - 38. <https://doi.org/10.1111/jscm.12136>
- Faraway, J. J. (2016). *Extending the linear model with R: generalized linear, mixed effects and non-parametric regression models* (2nd ed.). Boca Raton, Florida, USA: CRC Press. <https://doi.org/10.1201/b21296>
- Federal Reserve Bank of Saint Louis. (October de 2020). *Economic Research, FRED Economic Data*. Obtenido de <https://fred.stlouisfed.org/> Consultado: 02/10/2020
- Figlioli, B., Moreira Antonio, R., y Guasti Lima, F. (2019). Stock Price Synchronicity and Current and Potential Credit Ratings. *International Journal of Economics and Finance*, 11(10), 1 -16. <https://doi.org/10.5539/ijef.v11n10p1>
- Fontaine Rezende, F., da Silva Montezano, R. M., Nascimento de Oliveira, F., y de Jesus Lameira, V. (2017). Predicting financial distress in publicly-traded companies. *Revista Contabilidade & Finanças*, 28(75), 390 - 406. <https://doi.org/10.1590/1808-057x201704460>
- Hassani, B., y Zhao, X. (2015). Reconsidering Corporate Ratings. *Economic Notes: Review of Banking, Finance and Monetary Economics*, 44(2), 177-209. <https://doi.org/10.1111/ecno.12036>
- Hernandez Tinoco, M., Holmes, P., y Wilson, N. (2018). Polytomous response financial distress models: The role of accounting, market and macroeconomic variables. *International Review of Financial Analysis*, 59(October), 276 - 289. <https://doi.org/10.1016/j.irfa.2018.03.017>
- Hernandez-Tinoco, M., y Wilson, N. (2013). Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables. *International Review of Financial Analysis*, 30(December), 394 - 419. <https://doi.org/10.1016/j.irfa.2013.02.013>
- Hofbauer, G., Klimontowicz, M., y Nocoń, A. (2016). Basel III equity requirements and a contemporary rating approach. *Copernican Journal of Finance & Accounting*, 5(1), 91 - 105. <http://dx.doi.org/10.12775/CJFA.2016.005>
- Husein, M. F., y Pambekti, G. T. (2015). Precision of the models of Altman, Springate, Zmijewski, and Grover for predicting the financial distress. *Journal of Economics, Business, & Accountancy Ventura*, 17(3), 405 - 416. <http://dx.doi.org/10.14414/jebav.v17i3.362>
- Hussain, M. I., Nassir, A. M., Mohamad, S., & Hasan, T. (2005). Prediction of corporate financial distress of PN4 companies in Malaysia: A logistic model approach. *Journal of Restructuring Finance*, 2(02), 143-155. <https://doi.org/10.1142/s0219869x05000440>

- Instituto Nacional de Estadística y Geografía, INEGI. (October de 2020). *Banco de Información Económica (BIE, INEGI)*. Disponible en: <https://www.inegi.org.mx/sistemas/bie/> Consultado 05/10/2020.
- Kemper, K. J. (2020). Financial adjustments and credit rating changes. *Finance Research Letters*, 33(March), 101213. <https://doi.org/10.1016/j.frl.2019.06.011>
- Khemakhem, S., y Boujelbene, Y. (2018). Predicting credit risk on the basis of financial and non-financial variables and data mining. *Review of Accounting and Finance*, 17(3), 316 - 340. <https://doi.org/10.1108/RAF-07-2017-0143>
- Kisgen, D. J. (2019). The impact of credit ratings on corporate behavior: Evidence from Moody's adjustments. *Journal of Corporate Finance*, 58(October), 567-582. <https://doi.org/10.1016/j.jcorpfin.2019.07.002>
- Kliestik, T., Vrbka, J., y Rowland, Z. (2018). Bankruptcy prediction in Visegrad group countries using multiple discriminant analysis. *Equilibrium. Quarterly Journal of Economics and Economic Policy*, Vo. 13, No.3, 13(3), 569-593. <https://doi.org/10.24136/eq.2018.028>
- Koopman, S. J., y Lucas, A. (2008). A non-Gaussian panel time series model for estimating and decomposing default risk. *Journal of Business & Economic Statistics*, 26(4), 510 - 525. <https://doi.org/10.1198/073500108000000051>
- Korol, T., y Korodi, A. (2010). Predicting bankruptcy with the use of macroeconomic variables. *Economic computation and economic cybernetics studies and research*, 44(1), 201 - 221.
- Le, H. H., y Viviani, J.-L. (2018). Predicting bank failure: An improvement by implementing a machine-learning approach to classical financial ratios. *Research in International Business and Finance*, 44(April), 16 - 25. <https://doi.org/10.1016/j.ribaf.2017.07.104>
- Ledolter, J. (2013). *Data mining and business analytics with R*. Hoboken, New Jersey, USA: John Wiley & Sons. <https://doi.org/10.1002/9781118596289>
- Lee, C. F., y Yu, H.-C. (2020). Application of Discriminant Analysis, Factor Analysis, Logistic Regression, and KMV-Merton Model in Credit Risk Analysis. En C. F. Lee, y J. C. Lee, *Handbook of Financial Econometrics, Mathematics, Statistics, and Machine Learning* (págs. 4313 - 4328). Washington, DC: World Scientific. https://doi.org/10.1142/9789811202391_0126
- Lee, Y.-C. (2007). Application of support vector machines to corporate credit rating prediction. *Expert Systems with Applications*, 33(1), 67 - 74. <https://doi.org/10.1016/j.eswa.2006.04.018>
- Li, Z., Tian, Y., Li, K., Zhou, F., y Yang, W. (2017). Reject inference in credit scoring using semi-supervised support vector machines. *Expert Systems with Applications*, 74(May), 105 - 114. <https://doi.org/10.1016/j.eswa.2017.01.011>
- Linares-Mustarós, S., Coenders, G., y Vives-Mestres, M. (2018). Financial performance and distress profiles. From classification according to financial ratios to compositional classification. *Advances in Accounting*, 40(March), 1 - 10. <https://doi.org/10.1016/j.adiac.2017.10.003>
- Liou, D.-K., y Smith, M. (01 de May de 2006). *Macroeconomic variables in the identification of financial distress*. <http://dx.doi.org/10.2139/ssrn.900284>
- Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of finance*, 29(2), 449-470. <https://doi.org/10.2307/2978814>
- Mihalovic, M. (2016). Performance comparison of multiple discriminant analysis and logit models in bankruptcy prediction. *Economics & Sociology*, 9(4), 101 - 118. <https://doi.org/10.14254/2071-789X.2016/9-4/6>
- Mishra, S., y Bansal, R. (2019). Credit rating and its interaction with financial ratios: A study of BSE 500 companies. En T. Tripti, M. Kumar Dash y G. Agrawal, *Behavioral Finance and Decision-Making Models* (págs. 251 - 268). IGI Global. <https://doi.org/10.4018/978-1-5225-7399-9.ch014>
- Mpofu, T. R., y Nikolaidou, E. (2018). Determinants of credit risk in the banking system in Sub-Saharan Africa. *Review of development finance*, 8(2), 141-153. <https://doi.org/10.1016/j.rdf.2018.08.001>
- Nehrebecka, N. (2018). Predicting the default risk of companies. Comparison of credit scoring models: LOGIT vs Support Vector Machines. *Econometrics*, 22(2), 54 - 73. <https://doi.org/10.15611/ead.2018.2.05>
- Peres, C., y Antão, M. (2017). The use of multivariate discriminant analysis to predict corporate bankruptcy: A review." *Aestimatio. The IEB International Journal of Finance*, 14, 108 - 131. <https://doi.org/10.5605/IEB.14.6>

- Prodan-Palade, D. (2017). Bankruptcy risk prediction models based on artificial neural networks. *The Audit Financial journal*, 15(147), 110 - 121. <https://doi.org/10.20869/auditf/2017/147/418>
- R Core Team. (04 de 2020). R: A Language and Environment for Statistical Computing. R: A language and environment for statistical computing. 25, Vienna, Austria: R Foundation for Statistical Computing. Disponible en: <https://www.R-project.org/> Consultado: 01/09/2020
- Ramlall, I. (2018). Some Practical Issues in Credit Risk Modelling. En I. Ramlall, *The Banking Sector Under Financial Stability: Volume 2* (Vol. 11, págs. 205 - 211). Bingley, UK: Emerald Publishing Limited. <https://doi.org/10.1108/978-1-78769-681-520181009>
- Ripley, B. (2019). tree: Classification and Regression Trees. *R package version 1.0-40*. Obtenido de Disponible en: <https://CRAN.R-project.org/package=tree> Consultado: 01/09/2020
- Rokach, L., y Maimon, O. Z. (2014). *Data mining with decision trees: theory and applications*. Vol. 69. World scientific, 2008. (2nd ed., Vol. 69). Singapore: World Scientific. <http://dx.doi.org/10.1142/9789812771728>
- Ruxanda, G., Zamfir, C., y Muraru, A. (2018). Predicting financial distress for Romanian companies. *Technological and Economic Development of Economy*, 24(6), 2318 - 2337. <https://doi.org/10.3846/tede.2018.6736>
- Sbârcea, I. R. (2014). International Concerns for Evaluating and Preventing the Bank Risks—Basel I Versus Basel II Versus Basel III. *Procedia Economics and Finance*, 16(May), 336 -341. [https://doi.org/10.1016/S2212-5671\(14\)00811-9](https://doi.org/10.1016/S2212-5671(14)00811-9)
- Schmid, B. (2012). *Credit risk pricing models: Theory and practice*. Springer Science & Business Media, 2012. Munich: Springer. <https://doi.org/10.1007/978-3-540-24716-6>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61(January), 85 - 117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Tang, D. Y., & Yan, H. (2010). Market conditions, default risk and credit spreads. *Journal of Banking & Finance*, 34(4), 743-753. <https://doi.org/10.1016/j.jbankfin.2009.05.018>
- Tian, Y., Yong, Z., y Luo, J. (2018). A new approach for reject inference in credit scoring using kernel-free fuzzy quadratic surface support vector machines. *Applied Soft Computing*, 73(December), 96 - 105. <https://doi.org/10.1016/j.asoc.2018.08.021>
- Wagle, M., Yang, Z., y Benslimane, Y. (2017). Bankruptcy prediction using data mining techniques. *8th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES)* (págs. 1 - 4). Chonburi, Thailand: IEE. <https://doi.org/10.1109/ICTEmSys.2017.7958771>
- Wang, N. (2017). Bankruptcy prediction using machine learning. *Journal of Mathematical Finance* 7.04 (2017): 908., 7(4), 908 - 918. <https://doi.org/10.4236/jmf.2017.74049>
- West, D. (2000). Neural network credit scoring models. *Computers & Operations Research* 27.11-12, 27(11 - 12), 1131 - 1152. [https://doi.org/10.1016/S0305-0548\(99\)00149-5](https://doi.org/10.1016/S0305-0548(99)00149-5)
- Wojewodzki, M., Poon, W. P., y Shen, J. (2018). The role of credit ratings on capital structure and its speed of adjustment: An international study. *The European Journal of Finance*, 24(9), 735 - 760. <https://doi.org/10.1080/1351847X.2017.1354900>
- Woo, S.-H., Kwon, M.-S., y Yuen, K. F. (2020). Financial determinants of credit risk in the logistics and shipping industries. *Maritime Economics & Logistics*, In press, 1 - 23. <https://doi.org/10.1057/s41278-020-00157-4>
- Zamore, S., Djan, O., K., A. I., y Hobdari, B. (2018). Credit risk research: Review and agenda. *Emerging Markets Finance and Trade*, 54(4), 811 - 835. <https://doi.org/10.1080/1540496X.2018.1433658>
- Zhang, J., Bessler, D. A., y Leatham, D. J. (2013). Aggregate business failures and macroeconomic conditions: A VAR look at the US between 1980 and 2004. *Journal of Applied Economics*, 16(1), 179 - 202. [https://doi.org/10.1016/S1514-0326\(13\)60008-2](https://doi.org/10.1016/S1514-0326(13)60008-2)
- Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting research*, 22, 59 - 82. <https://doi.org/10.2307/2490859>