

Riesgo de fracaso empresarial en el sector C23 de manufactura del Ecuador

Risk of business failure in the C23 manufacturing sector in Ecuador

Luis Bernardo Tonon Ordóñez ¹, Iván Felipe Orellana Osorio ², Luis Gabriel Pinos Luzuriaga ³, Marco Antonio Reyes Clavijo ⁴

INFORMACIÓN DEL ARTÍCULO

Fecha de recepción: 1 de Febrero de 2022.

Fecha de aceptación: 22 de Abril de 2022.

¹ Magíster en Administración de Empresas, Universidad del Azuay. Docente-investigador, Universidad del Azuay - Ecuador.
E-mail: ltonon@uazuay.edu.ec
Código ORCID:
<https://orcid.org/0000-0003-2360-9911>

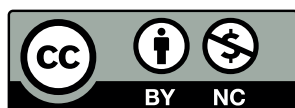
² Magíster en Administración de Empresas, Universidad del Azuay. Docente-investigador, Universidad del Azuay - Ecuador.
E-mail: ivano@uazuay.edu.ec
Código ORCID:
<https://orcid.org/0000-0001-6279-2734>

³ Magíster en Seguros y Riesgos Financieros, ESPOL. Docente-investigador, Universidad del Azuay - Ecuador.
E-mail: lpinos@uazuay.edu.ec
Código ORCID:
<https://orcid.org/0000-0002-3894-8652>

⁴ Magíster en Administración de Empresas, Universidad del Azuay. Docente-investigador, Universidad del Azuay - Ecuador.
E-mail: mreyes@uazuay.edu.ec
Código ORCID:
<https://orcid.org/0000-0001-5279-4234>

CITACIÓN: Tonon Ordóñez, L., Orellana Osorio, I., Pinos Luzuriaga, L., & Reyes Clavijo, M. (2022). Riesgo de fracaso empresarial en el sector C23 de manufactura del Ecuador. Podium, 41, 71–90.
doi:10.31095/podium.2022.41.5

ENLACE DOI:
<http://dx.doi.org/10.31095/podium.2022.41.5>



Resumen

El análisis de fracaso empresarial es importante, considerando que las empresas son el motor de la economía de un país. En el presente trabajo de investigación se estudia el riesgo de fracaso de las empresas del sector de fabricación de otros productos minerales no metálicos del Ecuador (CIU C23). La data consta en promedio de 183 empresas en el periodo 2009-2019. Partiendo del modelo de Ohlson, se proponen los modelos econométricos logit y probit para calcular la probabilidad de fracaso de las empresas del sector. En el modelo logit la probabilidad de fracaso se encuentra entre 3,67% y 8,42%, mientras que en el probit se encuentra entre 3,79% y 7,75%. Se destaca que a medida que se incrementa el tamaño empresarial, se reduce el riesgo de fracaso y que el año 2017 presenta menor riesgo; además, el modelo logit tiene mayor capacidad predictiva.

Palabras Clave:

Modelos econométricos, modelo logit, modelo probit, modelo de Ohlson, probabilidad de riesgo, riesgo de quiebra, productos minerales no metálicos.

Clasificación JEL: C1, C5, G1.

Abstract

The analysis of business failure is important, considering that companies are the engine of a country's economy. In the present research work, the risk of failure of companies in the manufacturing sector of other non-metallic mineral products in Ecuador (ISIC C23) is studied. The data consists of an average of 183 companies in the period 2009-2019. Starting from the Ohlson model (1980), logit and probit econometric models are proposed to calculate the probability of failure of companies in the sector. In the logit model, the probability of failure is between 3,67% and 8,42%, while in the probit, it is between 3,79% and 7,75%. It is highlighted that as the business size increases, the risk of failure is reduced and that the year 2017 presents less risk. In addition, the logit model has greater predictive capacity.

Keywords:

Econometric models, logit model, probit model, Ohlson model, risk probability, bankruptcy risk, non-metallic mineral products.

JEL Classification: C1, C5, G1.

Introducción

“La quiebra no siempre ocurre, pero cuando llega, afectará a un país ya sea económicamente o socialmente” (Kristanti y Herwany, 2017, p.26). La economía se basa en el buen funcionamiento de las empresas (Gregova y otros, 2020), es por esto que analizar y proponer indicadores de cierre se convierte en una importante herramienta para la toma de decisiones de los propietarios y otros grupos de interés; el objetivo principal sería crear sistemas de alerta temprana. Cabe mencionar que en la literatura se encuentran otros términos relacionados al fracaso, como son: cierre, bancarrota o insolvencia empresarial.

El estudio de fracaso empresarial ha evolucionado debido principalmente a la introducción de nuevas herramientas estadísticas que permiten estudiar y predecir más eficazmente acontecimientos futuros, en donde se busca mejorar la eficacia en el análisis de este riesgo, no solamente para predecir el cierre de una empresa, sino también para identificar posibles causas de esta problemática.

Para predecir dificultades financieras se han utilizado diferentes modelos de quiebra, esta predicción se ha vuelto un aspecto relevante para el gobierno corporativo (Siekelova y otros, 2018). Las metodologías utilizadas con más frecuencia para evaluar el fracaso empresarial han sido el análisis discriminante y modelos binomiales como logit y probit (Tascón y otros, 2018). La literatura internacional abarca

principalmente el desarrollo de modelos que se adaptan a la realidad de países desarrollados. Es así que, Altman y otros (1995) elaboraron el Emerging Market Scoring Model (EMS Model), el cual es una versión del modelo Z-score de Altman (1968) diseñado para empresas estadounidenses; este modelo ajustado incorporó las características crediticias particulares de las empresas de los mercados emergentes. También en el ámbito regional se destacan los trabajos de análisis de fracaso empresarial de Altman y otros (1979) en Brasil, Swanson y Tybout (1988) en Argentina, Pascale (1988) en las industrias manufactureras uruguayas. En Ecuador, Bermeo y Armijos (2021) aplicaron el modelo Z2 de Altman en la predicción de quiebra en las empresas de construcción de edificios en la provincia de Azuay.

En base a lo mencionado, el objetivo de la presente investigación es predecir la probabilidad de quiebra en las empresas pertenecientes al sector de fabricación de otros productos minerales no metálicos del Ecuador, por medio de los modelos propuestos logit y probit. Según el Banco Central del Ecuador (2020), a pesar que el aporte de este sector en la economía nacional es marginal, está relacionado con la construcción ya que genera bienes que son insumos para su actividad.

Revisión de literatura

De acuerdo a Castro y otros (2019), la bancarrota es el resultado de un estado crítico, en donde los pasivos de una empresa exceden al valor de sus activos; esto es consecuencia de factores como la

mala gestión administrativa, circunstancias macroeconómicas, iliquidez, entre otros. Para Sansores y otros (2020) la mortandad de empresas ha sido concebida como el fracaso en la gestión de los recursos por parte de los gerentes y/o propietarios. Los estudios del fracaso empresarial han evolucionado, principalmente por la aparición de nuevas herramientas estadísticas, en donde se destacan las siguientes etapas:

Análisis descriptivo del fracaso empresarial

En esta etapa las investigaciones se limitaban a describir las características de las empresas clasificadas como sanas y en bancarrota en función del uso de ratios financieros; sin embargo, esta tendencia carece de valor predictivo (Mares, 2001; Orellana y otros, 2020). Si la tendencia de los ratios (liquidez, endeudamiento, actividad y rentabilidad) eran desfavorables, la probabilidad de quiebra era más alta. Se destacan los trabajos de FitzPatrick (1932), quien inicialmente analizó el fracaso empresarial a través de estados financieros, además de otros investigadores como Smith y Winakor (1935), Merwin (1942), Jackendoff (1962) y Horrigan (1965).

Análisis predictivo del fracaso empresarial

Beaver (1966) propuso un análisis univariado para predecir la bancarrota. Posteriormente Altman (1968) introdujo el análisis discriminante múltiple (ADM) en esta área, encontrando diferencias significativas entre las empresas

quebradas y las no quebradas. Martin (1977) aplicó por primera vez la regresión logística a la construcción de alertas tempranas de quiebra bancaria. El autor extrajo como variables independientes un conjunto de 25 razones financieras de la base de datos nacional mantenida por el Banco de la Reserva Federal de Nueva York; estas variables pueden clasificarse en cuatro grandes grupos: riesgo de activos, liquidez, adecuación de capital y utilidades. En la etapa predictiva, Ohlson (1980) es considerado como pionero en el área económica en la aplicación del método de estimación de máxima verosimilitud, denominado logit condicional, basado en dos artículos inéditos no publicados: White y Turnbull, (1975a, 1975b) y un artículo de Santomero y Vinso (1977) que, según el autor, son los primeros estudios que desarrollaron lógica y sistemáticamente estimaciones probabilísticas de fracaso. El autor utilizó un conjunto de datos del periodo 1970-1976, que fueron obtenidos de los “estados financieros 10-K”, base de datos que permite verificar si la empresa entró en quiebra antes o después de la fecha de publicación.

Los principales hallazgos de Ohlson (1980) se resumen de la siguiente manera: los factores estadísticos que afectaron las probabilidades de bancarrota fueron el tamaño de la compañía, estructura financiera, medidas de desempeño y medidas de liquidez; y, los estudios previos parecen haber exagerado el poder predictivo de los modelos desarrollados y probados. El autor eligió la metodología econométrica del análisis logit condicional para evitar

problemas asociados con el análisis discriminante multivariante (MDA), como son:

- Requisitos estadísticos impuestos a las propiedades de distribución de los predictores. Por ejemplo, las matrices de varianza-covarianza de los predictores deben ser las mismas para ambos grupos (empresas fallidas y no fallidas). Además, un requisito de predictores distribuidos normalmente mitiga ciertamente el uso de variables independientes ficticias.

- El resultado de la aplicación de un modelo MDA es una puntuación que tiene poca interpretación intuitiva, ya que es básicamente un dispositivo de clasificación ordinal (discriminatorio).

- También existen ciertos problemas relacionados con los procedimientos de "emparejamiento" que se han utilizado típicamente en MDA. Las empresas que fracasan y las que no fracasan se combinan de acuerdo con criterios como el tamaño y la industria, y estos tienden a ser algo arbitrarios.

También se destaca en esta etapa a Zmijweski (1984), quien desarrolló una nueva fórmula a través de un modelo probit, y la exactitud de este modelo con los datos de su muestra fue del 99%. Entre los estudios más recientes se destacan Karminsky y Burekhin (2019), quienes compararon las capacidades de los modelos logit y probit, árboles de clasificación, bosques aleatorios y redes neuronales artificiales para predecir la quiebra de empresas de la industria de la construcción de Rusia en un horizonte de

un año. Pacheco y otros (2019) analizaron las variables financieras y no financieras estadísticamente relevantes para la predicción de la quiebra de las empresas del sector de la construcción civil en Portugal por medio de los modelos predictivos de quiebra *logit* y *probit*.

Kovacova y Kliestik (2017) realizaron un estudio empírico de la literatura relevante sobre la aplicación de métodos estadísticos matemáticos para la predicción de la quiebra de empresas eslovacas y proporcionar la comparación de la capacidad de predicción general de los modelos logit y probit durante al año 2015. Kitowski y otros (2022) analizaron la eficacia de predicción de fracaso de los modelos logit y discriminante que permitieron la evaluación del riesgo de quiebra en las empresas polacas susceptibles un año antes de su declaración de quiebra. En el ámbito regional, Gutiérrez (2019) realizó una investigación sobre la capacidad en el pronóstico del fracaso empresarial de los modelos de elección binaria para las Pymes en Colombia. Cruz y otros (2017) analizaron los modelos Poisson y Logístico en la asignación de probabilidades de incumplimiento a empresas mineras mexicanas. En el ámbito ecuatoriano, Cueva y otros (2017) analizaron la fragilidad financiera de las empresas a través de la estimación de los modelos probabilísticos logit y probit utilizando información de los balances financieros de 34.575 empresas tanto grandes, medianas, pequeñas y microempresas que han sido controladas por la Superintendencia de Compañías en el año 2013.

Metodologías basadas en inteligencia artificial

Existen también modelos no paramétricos para predecir el cierre empresarial, como son: redes neuronales artificiales, modelos hazard, modelos difusos, algoritmos genéticos y modelos híbridos, o combinaciones de los modelos anteriores. El uso de la Inteligencia Artificial busca mejorar la predicción de quiebra empresarial que se obtiene a partir de modelos clásicos utilizados anteriormente. Por ejemplo, Lane y otros (1986) introdujeron el uso del análisis de supervivencia para predecir problemas financieros en un sistema bancario; a diferencia del análisis discriminante múltiple, este modelo no contiene supuestos subyacentes, y es una herramienta útil por la capacidad para proporcionar una estimación del tiempo probable de falla; este artículo se centró en el modelo de riesgos proporcionales de Cox (1972). Por otra parte, Zadeh (1965, 1968) describió inicialmente los fundamentos matemáticos asociados a la teoría de conjuntos difusos y la lógica difusa. A pesar que las primeras aplicaciones de la lógica difusa se realizaron en el área de ingeniería de control, al igual que otras metodologías no paramétricas que inicialmente se utilizaron en otras áreas, se las empezaron a utilizar en el análisis de distintos tipos de riesgo financiero. Los resultados obtenidos a partir de estos modelos pretenden demostrar una mejor capacidad predictiva, sin embargo, no todos cumplen esta hipótesis. López y Sanz (2015) desarrollaron un modelo de redes neuronales para estudiar la

bancarrota de los bancos estadounidenses, considerando la reciente crisis financiera. Barboza y otros (2017) propusieron elevar el porcentaje de predicción mediante técnicas de aprendizaje automático como vectores de soporte automático, ensacado, refuerzo y bosques aleatorios (support vector machines, bagging, boosting, and random forest). Xue y otros (2018) para evitar el problema de la predicción de series de tiempo financieras, utilizaron la máquina de aprendizaje extrema basada en el mapeo de Fourier aleatorio. Lucanera y otros (2020) por medio de un enfoque de redes neuronales identificaron qué variables relacionadas con la teoría de la estructura de capital predicen el fracaso empresarial en el sector de la construcción español durante la crisis subprime.

Metodología

Información y datos de análisis

Se realizó el análisis según la Clasificación Internacional Industrial Uniforme (CIIU), la cual codifica al sector de fabricación de otros productos minerales no metálicos como “C23” (ver Tabla 1).

Tabla 1.

Clasificación del sector de fabricación de otros productos minerales no metálicos

CIIU	Descripción
C23	Fabricación de otros productos minerales no metálicos
C231	Fabricación de vidrio y productos de vidrio
C239	Fabricación de otros productos minerales no metálicos n.c.p.

Fuente: Superintendencia de Compañías, Valores y Seguros (2020).

La base de datos pasó por un proceso de depuración, en donde se eliminaron las empresas que no contaban con información financiera y aquellas que no presentaban actividad (información en “0” en el estado de resultados). En total se analizaron 2015 observaciones en el periodo 2009-2019, esto debido a la disponibilidad de información en el momento del inicio de la investigación. En la Tabla 2 se clasificaron las empresas activas y no activas; se consideraron no activas las que tuvieron la siguiente situación legal: cancelación o proceso de cancelación, disolución o proceso de disolución, inactivas y en liquidación.

Tabla 2.

Número de empresas del sector de fabricación de otros productos minerales no metálicos

Año	Activas	No activas	Total
2009	117	62	179
2010	122	58	180
2011	143	53	196
2012	152	42	194
2013	159	37	196
2014	169	35	204
2015	176	37	213
2016	167	27	194
2017	149	12	161
2018	139	8	147
2019	145	6	151
Total	1638	377	2015

Fuente: Superintendencia de Compañías, Valores y Seguros (2020).

Metodología de cálculo

Los modelos de regresión logística son modelos estadísticos que se utilizan cuando se desea describir la relación existente entre una variable respuesta de tipo categórico y un conjunto de variables explicativas categóricas o continuas. Estos modelos permiten estimar la

probabilidad de que un evento ocurra o no, prediciendo un resultado dependiente binario de un conjunto de variables independientes (Balaguer, 2009; Belyaeva, 2014). Ohlson (1980) estimó tres modelos, los cuales están compuestos por una intersección y nueve variables independientes. La descripción de las variables del modelo de Ohlson es la siguiente:

- X_1 (Tamaño) = Logaritmo (activos totales / índice del nivel de precios).
- X_2 = Pasivos Totales / Activos Totales.
- X_3 = Capital de Trabajo / Activos Totales.
- X_4 = Pasivo corriente / Activo corriente.
- X_5 = Dummy de solvencia: uno si los pasivos totales exceden los activos totales, cero en caso contrario.
- X_6 = Utilidad neta / Activos Totales.
- X_7 = Resultado operacional / Total de las obligaciones.
- X_8 = Dummy de rentabilidad: uno si el ingreso neto fue negativo durante los últimos dos años, cero en caso contrario.
- X_9 = $\frac{\text{Ingreso Neto}_t - \text{Ingreso Neto}_{t-1}}{|\text{Ingreso Neto}_t| + |\text{Ingreso Neto}_{t-1}|}$.

El modelo 1 predice la bancarrota dentro de un año; el modelo 2 predice la bancarrota dentro de dos años, dado que la compañía no fracasó en el año siguiente; y, el modelo 3 predice la bancarrota en uno o dos años. Los modelos 2 y 3 tienen estadísticas de bondad de ajuste algo más débiles. El modelo 1 presenta mejores resultados, ya que clasifica correctamente 96,12% de

las empresas.

$$\text{Modelo 1} = -1,32 - 0,407X_1 + 6,03X_2 - 1,43X_3 + 0,0757X_4 - 1,72X_5 - 2,37X_6 - 1,83X_7 + 0,28X_8 - 0,521X_9 \quad (1)$$

$$\text{Modelo 2} = 1,84 - 0,519X_1 + 4,76X_2 - 1,71X_3 - 0,297X_4 - 1,98X_5 - 2,74X_6 - 2,18X_7 - 0,780X_8 + 0,4218X_9 \quad (2)$$

$$\text{Modelo 3} = 1,13 - 0,478X_1 + 5,29X_2 - 0,990X_3 + 0,062X_4 - 1,91X_5 - 4,62X_6 - 2,25X_7 - 0,521X_8 + 0,212X_9 \quad (3)$$

Ohlson (1980) sugirió que el coeficiente de las variables X_1 , X_3 , X_6 , X_7 y X_9 es negativo. La variable X_1 hace referencia al tamaño, es decir que a medida que se incrementa el tamaño de la empresa se reduce el riesgo de bancarrota. Además, un mayor capital de trabajo y utilidad neta (frente a los activos totales, X_3 y X_6) de igual forma reducen el riesgo. En este grupo de indicadores también está la variable X_7 , la cual indica que una mayor utilidad operativa o menor nivel de deuda total disminuye el riesgo. Finalmente se encuentra la variable X_9 , variable que mide el cambio en la utilidad neta.

Por otra parte, el signo de las variables X_2 , X_4 y X_8 es positivo. En el caso de la variable X_2 , un mayor nivel de deuda frente a activos totales aumenta el riesgo de bancarrota. La variable X_4 de igual manera compara la deuda y activos, pero a nivel operativo, y al ser mayor este ratio se incrementa el riesgo. La variable X_8 es categórica, y evidentemente si el valor es positivo (1), existirá mayor riesgo de bancarrota. La variable X_5 el autor la consideró indeterminada. Esta variable

sirve como corrección de discontinuidad para la variable X_2 .

Si se tiene un conjunto de variables independientes ($X_1, X_2, X_3, \dots, X_9$), que clasifican en dos categorías a la variable Y (empresas insolventes o empresas no insolventes), la probabilidad de que una empresa i pertenezca a una de estas categorías será la combinación lineal:

$$Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_9 X_9 \quad (4)$$

Y será igual a:

$$P_1 = \frac{1}{1 + e^{-z}} \quad (5)$$

Es decir:

$$P(i) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_9 X_9)}} \quad (6)$$

$P(i)$ = Probabilidad de bancarrota

El resultado final obtenido del modelo está representado en términos de probabilidad. De acuerdo a Belyaeva (2014), en el caso del modelo 1, los resultados superiores a 0,5 pueden definir si una empresa quebrará dentro de dos años. Si se utiliza O como resultado del modelo:

$$O = \begin{cases} \leq 0,5 & \text{"Zona segura"} \\ > 0,5 & \text{"Dificultad financiera"} \end{cases} \quad (7)$$

Teniendo como base el modelo de Ohlson (1980), se propusieron en este trabajo los modelos econométricos *Logit* y *Probit*. Gujarati y Porter (2010) aseveraron que el modelo *logit* utiliza la función logística acumulativa, y el modelo de estimación que surge de una función de distribución acumulativa (FDA) normal se conoce comúnmente como modelo *probit*.

La variable dependiente del modelo se clasificó de la siguiente manera:

1 = Empresas en riesgo de insolvencia.

0 = Empresas que no se encuentran en riesgo de insolvencia.

Al no disponer de información sobre las empresas quebradas, el criterio que más se ajustó a los requerimientos de las empresas con alto riesgo de insolvencia son las que presentaron un patrimonio negativo y pérdida (ver Figura 1). Este supuesto se basó en lo que menciona la Superintendencia de Compañías, Valores y Seguros (2016): entre las principales causas de disolución que estipula la Ley de Compañías se encuentra la pérdida de 50% o más del capital social (compañías de responsabilidad limitada, anónimas, en comandita por acciones y de economía mixta).

Modelo Logit

Pece y otros (2012) indicó que el modelo de regresión logística binaria se expresa mediante el siguiente modelo

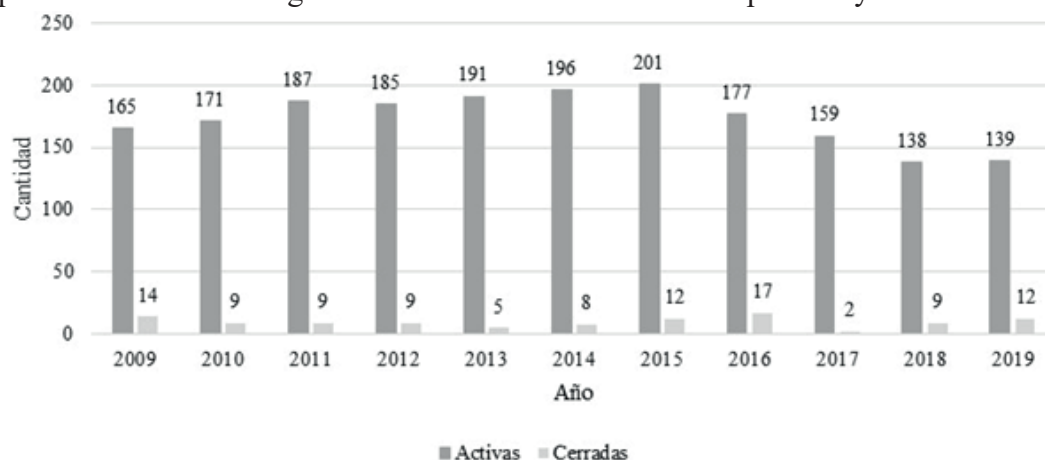


Figura 1. Empresas clasificadas como cerradas y activas.
Fuente: Superintendencia de Compañías, Valores y Seguros (2016).

lineal:

$$\ln\left(\frac{\pi_i}{1-\pi_i}\right) = \sum_{j=0}^p \beta_j X_{ij} \quad (8)$$

Donde:

π_i = Probabilidad de éxito de la variable binomial Y_i , sometida a las condiciones X_{i1}, \dots, X_{ip} .

Las variables X_{ij} (variables categóricas).

Los coeficientes del modelo β_1, \dots, β_p (método de máxima verosimilitud).

Modelo Probit

En el caso del modelo probit, el hecho de que una empresa esté en quiebra o no depende de un índice de conveniencia no observable o variable latente I_i , que está explicado por algunas variables, de manera que mientras mayor sea el I_i , mayor será la probabilidad de que una empresa quiebre.

$$I_i = B_0 + B_1 X_{i1} + B_2 X_{i2} + \dots + B_n X_{in} \quad (9)$$

Si $Y=1$, es una empresa quebrada. Para cada empresa hay un umbral crítico

que se denomina l_i^* , que al igual que l_i , no es observable, pero con la misma media y varianza, es posible estimar los parámetros del índice dado.

Entonces, si:

$$P_i = P(Y=1/X_i) = P_i = P(l_i^* \text{ sea menor o igual a } l_i) = P(Z \text{ menor o igual a } B_1 + B_2 X_{i1} + \dots + B_n X_{in}) = F(B_1 + B_2 X_{i1} + \dots + B_n X_{in})$$

Si la función de distribución de la normal $F(x)$ es:

$$F(l_i) = \frac{1}{\sqrt{2\pi}} \int_{-\alpha}^x e^{-z^2/2} dz \quad (10)$$

En este caso:

$$F(l_i) = \frac{1}{\sqrt{2\pi}} \int_{-\alpha}^{l_i} e^{-z^2/2} dz \quad (11)$$

$$F(l_i) = \frac{1}{\sqrt{2\pi}} \int_{-\alpha}^{B_1 + B_2 x_i + \dots + B_n X_{in}} e^{-z^2/2} dz \quad (12)$$

A partir de los modelos se obtuvo la probabilidad de fracaso de las empresas del sector C 23. Se pretende estimar la probabilidad de que ocurra un suceso en función de la dependencia de otras variables.

Resultados

En las Figuras 2 y 3 se presentan los modelos *logit* y *probit*, una vez aplicados los criterios mencionados en la metodología. Resultaron estadísticamente

significativas las siguientes variables: tamaño empresarial (X_1), el ratio pasivo total/activo total (X_2), capital de trabajo/activo total (X_3), la dummy de rentabilidad (X_8) y la variable X_9 .

Dependent Variable: VARIABLE_DEPENDIENTE
 Method: ML - Binary Logit (Newton-Raphson / Marquardt steps)
 Date: 05/05/21 Time: 17:49
 Sample: 1 2015
 Included observations: 2015
 Convergence achieved after 8 iterations
 Coefficient covariance computed using observed Hessian

Variable	Coefficient	Std. Error	z-Statistic	Prob.
X1_TAMANO_LOG_A_TOTAL_IPC_	-0.592933	0.125143	-4.738045	0.0000
X2_P_TOTAL_A_TOTAL	2.516572	0.320257	7.857973	0.0000
X3_CAPITAL_DE_TRABAJO_A_TOTAL	1.271885	0.307957	4.129418	0.0000
X8_DUMMY_RENTABILIDAD	2.016553	0.260376	7.744786	0.0000
X9_UNT_UNT_1_VALOS_ABSOLUTO	-1.469430	0.227248	-6.466196	0.0000
C	-4.117838	0.549837	-7.489196	0.0000

McFadden R-squared	0.387725	Mean dependent var	0.052605
S.D. dependent var	0.223300	S.E. of regression	0.177003
Akaike info criterion	0.258355	Sum squared resid	62.94230
Schwarz criterion	0.275055	Log likelihood	-254.2928
Hannan-Quinn criter.	0.264485	Deviance	508.5856
Restr. deviance	830.6497	Restr. log likelihood	-415.3248
LR statistic	322.0640	Avg log likelihood	-0.126200
Prob(LR statistic)	0.000000		

Obs with Dep=0	1909	Total obs	2015
Obs with Dep=1	106		

Figura 2. Modelo logit propuesto.

Fuente: Elaboración propia. Obtenido de: Software Eviews.

Dependent Variable: VARIABLE_DEPENDIENTE
 Method: ML - Binary Probit (Newton-Raphson / Marquardt steps)
 Date: 05/05/21 Time: 19:31
 Sample: 1 2015
 Included observations: 2015
 Convergence achieved after 7 iterations
 Coefficient covariance computed using observed Hessian

Variable	Coefficient	Std. Error	z-Statistic	Prob.
X1_TAMANO_LOG_A_TOTAL_IPC_	-0.294729	0.058962	-4.998660	0.0000
X2_P_TOTAL_A_TOTAL	1.054578	0.128688	8.194845	0.0000
X3_CAPITAL_DE_TRABAJO_A_TOTAL	0.743167	0.125871	5.904203	0.0000
X8_DUMMY_RENTABILIDAD	1.081580	0.130059	8.316084	0.0000
X9_UNT_UNT_1_VALOS_ABSOLUTO	-0.698697	0.108194	-6.457838	0.0000
C	-2.058921	0.245312	-8.393087	0.0000

McFadden R-squared	0.373964	Mean dependent var	0.052605
S.D. dependent var	0.223300	S.E. of regression	0.180953
Akaike info criterion	0.264028	Sum squared resid	70.21735
Schwarz criterion	0.280728	Log likelihood	-260.0081
Hannan-Quinn criter.	0.270157	Deviance	520.0163
Restr. deviance	830.6497	Restr. log likelihood	-415.3248
LR statistic	310.6334	Avg log likelihood	-0.128036
Prob(LR statistic)	0.000000		

Obs with Dep=0	1909	Total obs	2015
Obs with Dep=1	106		

Figura 3. Modelo probit propuesto.

Fuente: Elaboración propia. Obtenido de: Software Eviews.

La función de distribución logística (13), y la función de distribución normal (14).

$$P(i) = \frac{1}{1 + e^{-((-4.118) - (0.593 * \text{Tamaño}) + (2.517 * \frac{PT}{AT}) + (1.272 * \frac{CT}{AT}) + (2.017 * \text{Dummy de rent.}) - (1.469 * \frac{I_t - I_{t-1}}{ABS I_t + ABS I_{t-1}}))}} \quad (13)$$

$$F(I_i) = \frac{1}{\sqrt{2\pi}} \int_{-\alpha}^{-2.059 - (0.295 * \text{Tam.}) + (1.055 * \frac{PT}{AT}) + (0.743 * \frac{CT}{AT}) + (1.082 * \text{Dummy rent.}) - (0.7 * \frac{I_t - I_{t-1}}{ABS I_t + ABS I_{t-1}})} e^{-z^2/2} dz \quad (14)$$

En la Tabla 3 se analizaron los coeficientes de los modelos clásicos, *logit* y *probit*. Las variables X₁, X₂, X₈ y X₉ poseen los mismos signos (la interpretación ya se mencionó anteriormente). Sin embargo, la variable X₃ discrepa con la metodología clásica, ya que tiene signo positivo, pues Altman utilizó para su cálculo los datos de empresas cerradas, a diferencia del presente estudio en el cual se utilizó el total de la data de las empresas del sector.

En la Figura 4 se presentan los niveles de riesgo en las metodologías *logit* y *probit*, en donde se observa que se mantienen los mismos niveles (ligeras diferencias) y tendencia; se destaca que el año 2016 fue el más riesgoso. Los niveles de riesgo se encontraron entre 3,67% y 8,42% en el modelo *logit*, y 3,79 y 7,75% en el *probit*; estos valores fueron inferiores a los que se presentaron al aplicar la metodología clásica de Ohlson. (Ver Anexos 1 y 2).

Tabla 3.
Análisis de coeficientes de los modelos

Variable	Descripción	Metodología		
		Clásica	Logit	Probit
X1	Tamaño	-0,407	-0,593	-0,295
X2	Pasivo total / Activo total	6,03	2,517	1,055
X3	Capital de trabajo / Activo total	-1,43	1,272	0,743
X4	Pasivo corriente / Activo corriente	No significativa		
X5	Dummy de solvencia	No significativa		
X6	Utilidad neta/ Activos Totales	No significativa		
X7	Resultado operacional / Total de las obligaciones	No significativa		
X8	Dummy de rentabilidad	0,285	2,017	1,082
X9	Ingreso Neto _t - Ingreso Neto _{t-1} / Ingreso Neto _t + Ingreso Neto _{t-1}	-0,521	-1,469	-0,699
Constante		-1,32	-4,1178	-2,059

Fuente: Elaboración propia.

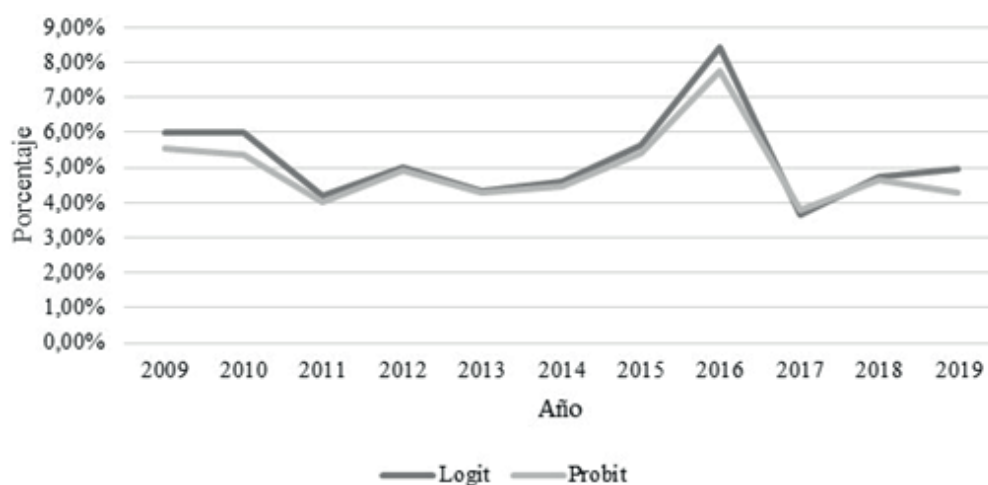


Figura 4. Probabilidad de fracaso empresarial del sector C23.

Fuente: Elaboración propia.

En la Figura 5 se presenta el riesgo de fracaso de las empresas clasificadas como cerradas, (criterios mencionados en la metodología). Se destacó que se mantuvo la misma tendencia en los modelos; además, las empresas cerradas tuvieron valores que oscilaron entre 30,13% y 54,13% en el modelo *logit*, y de 23,52% y 47,66% en el modelo *probit* (ver resultados en el Anexo 3).

A medida que se incrementa el tamaño empresarial, se reduce el riesgo de fracaso. Esta relación se mantuvo en las dos metodologías (Ver Figura 6).

En la Tabla 4 se muestra la probabilidad de fracaso en los dos subsectores que son parte del sector analizado. En las metodologías alternativas el subsector C239 fue más riesgoso. Cabe destacar, que no existieron diferencias significativas.

Al analizar las provincias con mayor concentración de empresas del sector, se observó que Pichincha tuvo valores más altos en los modelos propuestos (*Logit* = 6,54% y *Probit* = 5,91%), seguido de Azuay (*Logit* = 5,85% y *Probit* = 5,75%); Guayas tuvo empresas con una menor




Figura 5. Probabilidad de fracaso de empresas cerradas.
Fuente: Elaboración propia.

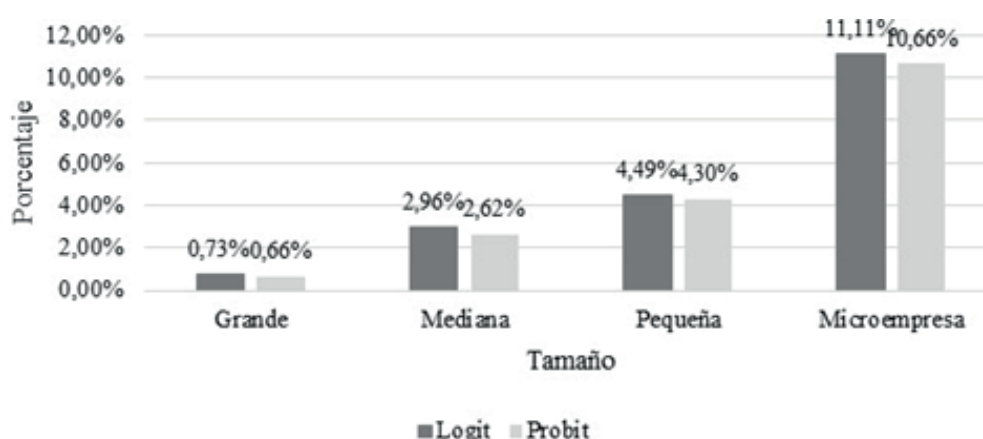


Figura 6. Probabilidad de fracaso por tamaño empresarial.
Fuente: Elaboración propia.

probabilidad de fracaso (*Logit* = 3,59 % y *Probit* = 3,56%) (Ver Tabla 5).

Tabla 4.

Probabilidad de fracaso en los subsectores C231 y C239

Año	C231		C239	
	Logit	Probit	Logit	Probit
2009	8,10%	7,60%	5,50%	5,06%
2010	5,81%	5,15%	6,02%	5,40%
2011	4,14%	4,28%	4,22%	3,94%
2012	5,17%	5,29%	4,98%	4,85%
2013	3,31%	3,48%	4,57%	4,46%
2014	8,06%	7,53%	3,89%	3,87%
2015	4,40%	3,80%	5,87%	5,74%
2016	4,19%	4,28%	9,26%	8,44%
2017	2,51%	2,77%	3,90%	3,98%
2018	4,64%	4,49%	4,75%	4,67%
2019	6,04%	4,05%	4,76%	4,31%
Promedio	5,17%	4,88%	5,28%	5,01%

Fuente: Elaboración propia.

Tabla 5.

Riesgo de insolvencia provincial

Año	Azuay		Guayas		Pichincha	
	Logit	Probit	Logit	Probit	Logit	Probit
2009	11,19%	10,15%	3,47%	3,60%	7,15%	6,37%
2010	2,67%	2,57%	2,59%	2,69%	9,91%	9,04%
2011	3,04%	3,13%	2,41%	2,46%	6,84%	6,14%
2012	4,34%	4,41%	2,96%	3,30%	7,37%	6,61%
2013	7,49%	7,74%	2,70%	2,74%	2,71%	2,69%
2014	4,31%	4,59%	3,90%	3,72%	4,56%	4,49%
2015	7,03%	6,72%	4,51%	4,35%	6,78%	6,48%
2016	12,64%	11,84%	8,14%	7,26%	6,61%	6,06%
2017	3,04%	3,60%	1,62%	1,77%	6,43%	6,14%
2018	3,92%	3,75%	3,73%	3,74%	5,64%	5,29%
2019	2,72%	2,82%	2,42%	2,71%	7,79%	5,24%
Promedio	5,85%	5,75%	3,59%	3,56%	6,54%	5,91%

Fuente: Elaboración propia.

Es importante mencionar cómo está la capacidad predictiva de los modelos estimados (Anexo 4), pero antes es necesario conocer que el punto de corte planteado para categorizar a las empresas insolventes de las solventes es del 0,50, es decir, que a todas las predicciones por arriba de una probabilidad de 0,50 son insolventes mientras que todas las que estén por debajo de 0,50 serán empresas solventes. Aunque no hay un criterio claro para definir este punto de corte,

autores como Camm y otros (2019) señalan que ante ausencia de esta información una forma adecuada es colocar el 0,50 como punto de corte para clasificar los resultados.

En general el modelo *Logit* estimado predijo un 95,98% de las observaciones (99,48% con las empresas que no quiebran y un 33,02% en las empresas que quebraron), mientras que el modelo *Probit* en 95,53% en su conjunto (predice correctamente en el 99,58% de las veces empresas que no quiebran y un 22,64% a las que quebraron).

La pregunta que surge es: ¿Qué pasaría si se mueve el punto de corte para separar a las empresas quebradas de las no quebradas? En las Tablas 6 y 7, se presentan los posibles resultados de la capacidad predictora del modelo tanto para *Logit* como para *Probit*:

Tabla 6.

Capacidad predictora del modelo *Logit*

Punto de corte	% de Correctos (dep=1)	% de Correctos (dep=0)	% de predicción total
0,50	33,02	99,48	95,98
0,40	37,74	99,42	96,18
0,30	46,23	98,8	96,03
0,20	58,49	97,49	95,43
0,10	75,47	92,61	91,71
0,05	90,57	83,71	84,07

Fuente: Elaboración propia.

Tabla 7.

Capacidad predictora del modelo *Probit*

Punto de corte	% de Correctos (dep=1)	% de Correctos (dep=0)	% de predicción total
0,5	22,64	99,58	95,53
0,4	28,3	99,58	95,83
0,3	36,79	98,9	95,63
0,2	52,83	97,17	94,84
0,1	71,7	91,99	90,92
0,05	87,74	81,35	81,69

Fuente: Elaboración propia.

Una vez realizados los análisis pertinentes se pudo ver que, al utilizar un punto de corte del 0,40, en ambos modelos su capacidad predictora global aumentó, aunque a medida que baja el valor del punto de corte la posibilidad de obtener falsos positivos o negativos varía.

Conclusiones

La construcción de un modelo de quiebra implica muchos temas que se deben resolver, con el objetivo de predecir el fracaso empresarial las principales preguntas que se pueden hacer son: ¿Cuándo la empresa ha caído en la quiebra? ¿Cuáles son los factores y los signos de fracaso? ¿Cuándo se ve obligada la empresa a cerrar sus actividades? (Kubičková y Nulíček, 2016). Para Ruiz y otros (2022), las empresas se encuentran en un escenario crítico en donde no solo luchan con la competencia, sino que también se ven afectadas por factores externos como la inflación, aspectos políticos, sociales y culturales, además de un fenómeno epidemiológico (Covid-19). En la investigación se describe la evolución que ha tenido el análisis de insolvencia, pasando desde una etapa descriptiva que se limitó al análisis de ratios financieros como predictores de la salud financiera, hasta pasar a una etapa descriptiva que pretende crear un sistema de alerta temprana para mitigar los efectos del fracaso empresarial. Así también se mencionan técnicas nuevas basadas en inteligencia artificial. Las metodologías nuevas, en teoría, clasifican más efectivamente empresas fracasadas y no fracasadas que los modelos estadísticos

paramétricos clásicos, sin embargo, es un tema a debatir. Por ejemplo, en la investigación de Boritz y Kennedy (1995) se descubrió que el rendimiento de las redes neuronales no era superior a las técnicas convencionales como el análisis discriminante de Altman (1968) y *logit* de Ohlson (1980). Shumway (2001) comparó el desempeño de un modelo de riesgo (hazard model) contra el modelo Altman, y concluyó que el modelo de riesgo tiene mayor capacidad predictiva y precisión que el modelo Altman y que se puede obtener una precisión aún mayor con un conjunto alternativo de variables explicativas. Belyaeva (2014) indica que el modelo O-Score se obtuvo después de evaluar más de 2000 empresas, en comparación con Altman Z-Score, donde fueron 66 empresas, por lo que concluye que el O-Score es más preciso para predecir el fracaso en un plazo de 2 años.

Al tener en cuenta el análisis *logit* propuesto por Ohlson (1980), en los tres modelos desarrollados, el tamaño aparece como un predictor importante. Por otra parte, Castro y otros (2019) asevera que uno de los principales determinantes para el incumplimiento de obligaciones es la deuda. Otros factores a considerar son la información y localización de la investigación. De acuerdo a Gregova y otros (2020), los resultados de muchas investigaciones confirman que la fiabilidad y la precisión predictiva de los modelos disminuyen si se utilizan en diferentes entornos nacionales y horizontes de tiempo que aquellos en los que se formaron originalmente. Bajo este escenario, se puede concluir que no existe un modelo o metodología perfecta para

analizar y predecir el fracaso empresarial, sino más bien se deben adaptar estos modelos a las circunstancias e información que se dispone.

En esta investigación se proponen dos metodologías: *logit* y *probit*. De acuerdo a Belyaeva (2014), en el modelo *logit* Z sigue una distribución logística, y en el modelo *probit* Z sigue una distribución normal estándar; se comportan de manera similar, excepto que la distribución logística tiende a tener cola ligeramente más plana. Para definir la variable dependiente de los modelos para el caso ecuatoriano, al no disponer de información de empresas quebradas se utilizaron los supuestos de pérdida y patrimonio negativo para la clasificación; cabe mencionar que Ohlson (1980) utilizó para sus cálculos una muestra final de 105 empresas en quiebra y 2058 empresas no quebradas. El resultado final del modelo indica la probabilidad que tienen las empresas del sector de fabricación de otros productos minerales no metálicos del Ecuador de fracasar o caer en bancarrota. Se debe indicar que los coeficientes estimados en los modelos *logit* y *probit* no son comparables.

En el análisis de los resultados de los dos modelos, se destaca que la mayor probabilidad de riesgo de quiebra se da en el año 2016: *logit* = 8,42%, y *probit* = 7,75%. Si se comparan estos valores con el modelo clásico de Ohlson (ver Anexo 1), los valores se incrementan de forma considerable (valores superiores al 53,58% en todo el periodo); esta diferencia se debe a que en los modelos propuestos no intervienen las nueve variables del

modelo de Ohlson. Otro factor a analizar es el resultado general o promedio, ya que, al desagregar los resultados, las empresas clasificadas como cerradas presentan valores superiores al promedio general: 30,13% (*logit*) y 23,52% (*probit*); sin embargo, al existir una mayor cantidad de empresas activas en el análisis (ver Figura 1), el valor medio tiende a bajar, afectando de esta manera al promedio general que se mencionó anteriormente. Cabe indicar que el modelo *logit* presenta una mayor capacidad predictiva (95,98%) que el modelo *probit* (95,53%) (Ver Anexos 4 y 5). Además, el valor de corte o punto discriminatorio entre empresas quebradas y no quebradas es de 50%, esto de acuerdo a Camm y otros (2019).

Se analizó también la probabilidad de fracaso por tamaño empresarial, considerando que es una de las variables que incluye Ohlson (2010) dentro de su modelo e indicando que las empresas grandes son menos riesgosas; bajo este escenario, Kuběnka y Myšková (2019) aseveraron que los indicadores más importantes de predicción de quiebras pueden describirse como indicadores de tamaño de la empresa, utilizando el valor de las ventas y el total activos. En el análisis provincial, Guayas presentó los niveles más bajos de riesgo, seguida de Azuay y Pichincha.

Los modelos de regresión logística son muy populares para analizar el fracaso empresarial. En el caso de la utilización de modelos logísticos, estos evitan problemas asociados al análisis discriminante multivariante (MDA), tal como se menciona en la investigación.

Además, este modelo, si se compara con modelos que utilizan inteligencia artificial, presenta resultados favorables. Aquí, es importante analizar la información disponible y el lugar en donde se realiza el estudio, ya que estos factores son críticos y pueden influir en los resultados obtenidos. En el caso de los modelos propuestos, estos fueron obtenidos a partir de información financiera de empresas ecuatorianas, obteniéndose de esta manera las variables estadísticamente significativas que son parte de los modelos *logit* y *probit* que predicen la probabilidad de fracaso empresarial, esto, bajo un contexto o escenario más acorde al de la situación del país, considerando que el modelo original se lo elaboró bajo un contexto de países desarrollados.

Contribución de autores

L.B.T.O. Revisión de literatura, metodología, análisis de datos, discusión y conclusiones, y revisión de redacción.

I.F.O.O. Metodología, análisis de datos, discusión y conclusiones, y revisión de redacción.

L.G.P.L. Metodología, análisis de datos, discusión y conclusiones, y revisión de redacción.

M.A.R.C. Metodología, análisis de datos, discusión y conclusiones, y revisión de redacción.

Referencias

Altman, E. (1968). Financial ratios, discriminant

analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23, 589-609. <https://doi.org/10.2307/2978933>

Altman, E., Baidya, T., y Ribeiro, L. (1979). Assessing Potential Financial Problems for firms in Brazil. *Journal of International Business Studies*, 10, 9-24. <https://doi.org/10.1057/palgrave.jibs.8490787>

Altman, E., Hartzell, J., y Peck, M. (1995). Emerging market corporate bonds - a scoring system. *Salomon Brothers Inc, New York University*, 391-400. https://doi.org/10.1007/978-1-4615-6197-2_25

Balaguer, P. (2009). Una explicación del rendimiento estudiantil universitario mediante modelos de regresión logística. *Visión Gerencial*, 0(2), 415-427.

Banco Central del Ecuador. (2020). *Anuario estadístico 40*. <https://contenido.bce.fin.ec/documentos/PublicacionesNotas/Catalogo/Anuario/Boletinuario.htm>

Barboza, F., Kimura, H., y Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405-417. <https://doi.org/10.1016/j.eswa.2017.04.006>

Beaver, W. (1966). Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, 4, 71-111. <https://doi.org/https://doi.org/10.2307/2490171>

Belyaeva, E. (2014). On a new logistic regression model for bankruptcy prediction in the IT branch. Project Report 2014:35, Uppsala Universitet.

Bermeo, A., y Armijos, J. (2021). Predicción de quiebra bajo el modelo Z2 Altman en empresas de construcción de edificios residenciales de la provincia del Azuay. *Revista Economía y Política*, 33.

Boritz, E., y Kennedy, D. (1995). Effectiveness of neural network types for prediction of business failure. *Expert Systems with Applications*, 9(4), 503-512. [https://doi.org/10.1016/0957-4174\(95](https://doi.org/10.1016/0957-4174(95)

00020-8

Camm, J., Cochran, J., Fry, M., Ohlmann, J., y Anderson, D. (2019). *Business Analytics: descriptive, predictive, prescriptive*. Cengage Learning.

Castro, Y., Huertas, C., Obando, C., y Valencia, C. (2019). Análisis de supervivencia para predicción de bancarrota: Caso de las industrias minoristas en Colombia. *Espacios*, 40(1), 18.

Cox, D. (1972). Regression Models and Life-Tables. *Imperial College, London*, 34(2), 187-202. <https://doi.org/10.1111/j.2517-6161.1972.tb00899.x>

Cruz, S., Gavira, N., y García, R. (2017). Eficiencia de los modelos Poisson y Logístico en la asignación de probabilidades de incumplimiento a empresas mineras mexicanas. *Revista Mexicana de Economía y Finanzas*, 12(1), 1–21.

Cueva, D., Cortes, S., Tapia, R., Tabi, W., Torres, J., Maza, C., Uyaguari, K., y Gonzalez, M. (2017). Fragilidad Financiera de las Empresas - Estimación de un Modelo probabilístico LOGIT y PROBIT: Caso Ecuatoriano. *Iberian Conference on Information Systems and Technologies, CISTI*. <https://doi.org/10.23919/CISTI.2017.7975927>

FitzPatrick, P. (1932). Average Ratios of Twenty Representative Industrial Failures. *The Certified Public Account*, 13-18.

Gregova, E., Valaskova, K., Adamko, P., Tumpach, M., y Jaros, J. (2020). Predicting Financial Distress of Slovak Enterprises: Comparison of Selected Traditional and Learning Algorithms Methods. *Sustainability*, 12(10), 3954. <https://doi.org/10.3390/su12103954>

Gujarati, D., y Porter, D. (2010). *Econometría* (5.a ed.). McGraw-Hill.

Gutiérrez, Y. (2019). Modelos de elección binaria aplicados al pronóstico del fracaso empresarial para las Pymes en Colombia. *Universidad Nacional de Colombia*.

Horrigan, J. (1965). Some Empirical Bases of Financial Ratio Analysis. *American Accounting Association*, 40(3), 558-568.

Jackendoff, N. (1962). A Study of Published Industry Financial and Operating Ratios. En *Temple University, Bureau of Economic and Business Research*.

Karminsky, A., y Burekhin, R. (2019). Comparative analysis of methods for forecasting bankruptcies of Russian construction companies. *Business Informatics*, 13(3), 52–66. <https://doi.org/10.17323/1998-0663.2019.3.52.66>

Kitowski, J., Kowal, A., y Lichota, W. (2022). Identifying Symptoms of Bankruptcy Risk Based on Bankruptcy Prediction Models—A Case Study of Poland. *Sustainability (Switzerland)*, 14(3). <https://doi.org/10.3390/su14031416>

Kovacova, M., y Kliestik, T. (2017). Logit and Probit application for the prediction of bankruptcy in Slovak companies. *Equilibrium*, 12(4), 775–791. <https://doi.org/10.24136/eq.v12i4.40>

Kristanti, F., y Herwany, A. (2017). Corporate Governance, Financial Ratios, Political Risk and Financial Distress: A Survival Analysis. *Accounting & Finance Review*, 2(2), 26-34. [https://doi.org/10.35609/afr.2017.2.2\(4\)](https://doi.org/10.35609/afr.2017.2.2(4))

Kuběnka, M., y Myšková, R. (2019). Obvious and hidden features of corporate default in bankruptcy models. *Journal of Business Economics and Management*, 20(2), 368–383. <https://doi.org/10.3846/jbem.2019.9612>

Kubíčková, D., y Nulíček, V. (2016). Predictors of Financial Distress and Bankruptcy Model Construction. *International Journal of Management Science and Business Administration*, 2(6), 34–41. <https://doi.org/10.18775/ijmsba.1849-5664-5419.2014.26.1003>

Lane, W., Looney, S., y Wansley, J. (1986). An application of the cox proportional hazards model to bank failure. *Journal of Banking and Finance*, 10(4), 511-531. [https://doi.org/10.1016/S0378-4266\(86\)80003-6](https://doi.org/10.1016/S0378-4266(86)80003-6)

- López, F., y Sanz, I. (2015). Bankruptcy visualization and prediction using neural networks: A study of U.S. commercial banks. *Expert Systems with Applications*, 42(6), 2857–2869. <https://doi.org/10.1016/j.eswa.2014.11.025>
- Lucanera, J., Fabregat-Aibar, L., Scherger, V., y Vigier, H. (2020). Can the SOM analysis predict business failure using capital structure theory? Evidence from the subprime crisis in Spain. *Axioms*, 9(2). <https://doi.org/10.3390/AXIOMS9020046>
- Mares, A. (2001). *Análisis de las dificultades financieras de las empresas en una economía emergente: Las bases de datos y las variables independientes en el sector hotelero de la bolsa mexicana de valores* [Tesis doctoral]. Universitat Autònoma de Barcelona.
- Martin, D. (1977). Early warning of bank failure. A logit regression approach. *Journal of Banking and Finance*, 1(3), 249-276. [https://doi.org/10.1016/0378-4266\(77\)90022-X](https://doi.org/10.1016/0378-4266(77)90022-X)
- Merwin, C. (1942). Financing Small Corporations in Five Manufacturing Industries, 1926-36. *Journal of the American Statistical Association*, 39(225), 129-130.
- Ohlson, J. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18(1), 109. <https://doi.org/10.2307/2490395>
- Orellana, I., Tonon, L., Reyes, M., Pinos, L., y Cevallos, E. (2020). *Riesgos financieros en el sector manufacturero del Ecuador* (1.a ed.). Casa Editora Universidad del Azuay.
- Pacheco, L., Rosa, R., y Oliveira, F. (2019). Risco de Falência de pme: evidência no setor da construção em Portugal. *Contabilidade y Finanzas*, 71, 143–157. <https://doi.org/10.15446/innovar.v29n71.76401>
- Pascale, R. (1988). A Multivariate Model to Predict Firm Financial Problems: the Case of Uruguay. *Studies in Banking and Finance*, 7, 171–182.
- Pece, M., Acosta, M., Saavedra, S., y Bruno, C. (2012). Aplicación de la regresión logística en un estudio de emergencia de plántulas de Algarrobo blanco (*Prosopis alba* Griseb.) en vivero, bajo diferentes concentraciones salinas. *Quebracho*, 20(2), 78-84.
- Ruiz, E., Salazar, J., Huerta, I., Vadivia, M., Man, y Cárdenas, U. (2022). Desarrollo de las capacidades empresariales: influencia en el crecimiento económico de las MiPyMES mexicanas. RAN. *Revistas Academia y Negocios*, 8(1), 1–14. <https://doi.org/10.29393/ran8-1dcem50001>
- Sansores, E., Navarrete, J., Alvarado, L., y Licandro, O. (2020). Diagnóstico situacional en microempresas mexicanas: Fracaso o sobrevivencia empresarial. *Revista de Ciencias Sociales*, XXVI. <https://doi.org/10.31876/rcs.v26i1.31311>
- Santomero, A., y Vinso, D. (1977). Estimating the Probability of Failure for Commercial Banks and the Banking System. *Journal of Banking and Finance*, 185-205. [https://doi.org/https://doi.org/10.1016/0378-4266\(77\)90006-1](https://doi.org/https://doi.org/10.1016/0378-4266(77)90006-1)
- Shumway, T. (2001). Forecasting bankruptcy more accurately: A simple hazard model. *The Journal of Business*, 74(1), 101-124. <https://doi.org/10.2139/ssrn.171436>
- Sikelova, A., Klietk, T., y Adamko, P. (2018). Predictive Ability of Chosen Bankruptcy Models: A Case Study of Slovak Republic. *Economics and Culture*, 15(1), 105–114. <https://doi.org/10.2478/jec-2018-0012>
- Smith, R., y Winakor, A. (1935). *Changes in the Financial Structure of Unsuccessful Corporations*. Bureau of Business Research, bulletin number 51.
- Superintendencia de Compañías, Valores y Seguros. (2016). *Reglamento sobre inactividad, disolución, liquidación, reactivación y cancelación de compañías nacionales y sucursales extranjeras*. Lexis.
- Superintendencia de Compañías, Valores y

Seguros. (2020). *Portal de información*. https://appscvsmovil.supercias.gob.ec/portallInformacion/sector_societario.zul

Swanson, E., y Tybout, J. (1988). Industrial bankruptcy determinants in Argentina. *Journal of Banking and Finance*, 7, 1–25.

Tascón, M., Castaño, F., y Castro, P. (2018). A new tool for failure analysis in small firms: frontiers of financial ratios based on percentile differences (PDFR). *Revista Española de Financiación y Contabilidad*, 47(4), 433–463. <https://doi.org/10.1080/02102412.2018.1468058>

White, R., y Turnbull, M. (1975a). The Probability of Bankruptcy: American Railroads. *Working paper, Institute of Finance and Accounting, London University Graduate School of Business*.

White, R., y Turnbull, M. (1975b). The Probability of Bankruptcy for American Industrial Firms. *Working paper*.

Xue, J., Zhou, S. H., Liu, Q., Liu, X., y Yin, J. (2018). Financial time series prediction using ℓ_2, ℓ_1 -RF-ELM. *Neurocomputing*, 277, 176–186. <https://doi.org/10.1016/j.neucom.2017.04.076>

Zadeh, L. (1965). Fuzzy Sets. *Information and Control*, 8(3), 338-353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)

Zadeh, L. (1968). Fuzzy algorithms. *Information and Control*, 12(2), 94-102. [https://doi.org/10.1016/S0019-9958\(68\)90211-8](https://doi.org/10.1016/S0019-9958(68)90211-8)

Zmijweski, M. (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>

Anexos

Anexo 1.

Riesgo de fracaso – Metodología clásica

Año	Empresas		
	Total	Activas	Cerradas
2009	59,87%	56,62%	98,19%
2010	58,95%	56,88%	98,32%
2011	58,01%	56,07%	98,29%
2012	53,68%	51,53%	97,79%
2013	55,95%	54,84%	98,07%
2014	58,99%	57,37%	98,68%
2015	55,79%	53,30%	97,63%
2016	62,54%	59,16%	97,72%
2017	53,58%	53,01%	98,66%
2018	54,85%	52,10%	97,09%
2019	57,64%	54,13%	98,26%
Promedio	57,33%	55,07%	97,99%

Fuente: Elaboración propia.

Anexo 2.

Riesgo de fracaso – Metodologías *logit* y *probit*

Año	Metodología	
	Logit	Probit
2009	6,01%	5,55%
2010	5,98%	5,35%
2011	4,20%	4,00%
2012	5,02%	4,93%
2013	4,34%	4,29%
2014	4,59%	4,48%
2015	5,62%	5,42%
2016	8,42%	7,75%
2017	3,67%	3,79%
2018	4,74%	4,64%
2019	4,94%	4,27%
Promedio	5,26%	4,99%

Fuente: Elaboración propia.

Anexo 3.

Riesgo de fracaso de empresas cerradas

Año	Logit	Probit
2009	38,36%	31,54%
2010	40,92%	33,85%
2011	30,13%	23,80%
2012	54,53%	47,66%
2013	33,91%	28,88%
2014	34,65%	26,16%
2015	38,27%	30,57%
2016	49,18%	41,39%
2017	36,07%	26,23%
2018	31,30%	27,65%
2019	34,52%	23,52%
Promedio	39,41%	32,05%

Fuente: Elaboración propia.

Anexo 4.

Capacidad predictiva del modelo logit

Expectation-Prediction Evaluation for Binary Specification
Equation: UNTITLED
Date: 05/05/21 Time: 17:53
Success cutoff: C = 0.5

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)<=C	1899	71	1970	1909	106	2015
P(Dep=1)>C	10	35	45	0	0	0
Total	1909	106	2015	1909	106	2015
Correct	1899	35	1934	1909	0	1909
% Correct	99.48	33.02	95.98	100.00	0.00	94.74
% Incorrect	0.52	66.98	4.02	0.00	100.00	5.26
Total Gain*	-0.52	33.02	1.24			
Percent Gain...	NA	33.02	23.58			

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	1844.77	64.23	1909.00	1808.58	100.42	1909.00
E(# of Dep=1)	64.23	41.77	106.00	100.42	5.58	106.00
Total	1909.00	106.00	2015.00	1909.00	106.00	2015.00
Correct	1844.77	41.77	1886.55	1808.58	5.58	1814.15
% Correct	96.64	39.41	93.63	94.74	5.26	90.03
% Incorrect	3.36	60.59	6.37	5.26	94.74	9.97
Total Gain*	1.90	34.15	3.59			
Percent Gain...	36.04	36.04	36.04			

*Change in "% Correct" from default (constant probability) specification
**Percent of incorrect (default) prediction corrected by equation

Fuente: Elaboración propia.

Anexo 5.

Capacidad predictiva del modelo probit

Expectation-Prediction Evaluation for Binary Specification
Equation: UNTITLED
Date: 05/05/21 Time: 19:33
Success cutoff: C = 0.5

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
P(Dep=1)<=C	1901	82	1983	1909	106	2015
P(Dep=1)>C	8	24	32	0	0	0
Total	1909	106	2015	1909	106	2015
Correct	1901	24	1925	1909	0	1909
% Correct	99.58	22.64	95.53	100.00	0.00	94.74
% Incorrect	0.42	77.36	4.47	0.00	100.00	5.26
Total Gain*	-0.42	22.64	0.79			
Percent Gain...	NA	22.64	15.09			

	Estimated Equation			Constant Probability		
	Dep=0	Dep=1	Total	Dep=0	Dep=1	Total
E(# of Dep=0)	1842.48	72.03	1914.51	1808.58	100.42	1909.00
E(# of Dep=1)	66.52	33.97	100.49	100.42	5.58	106.00
Total	1909.00	106.00	2015.00	1909.00	106.00	2015.00
Correct	1842.48	33.97	1876.45	1808.58	5.58	1814.15
% Correct	96.52	32.05	93.12	94.74	5.26	90.03
% Incorrect	3.48	67.95	6.88	5.26	94.74	9.97
Total Gain*	1.78	26.79	3.09			
Percent Gain...	33.76	28.27	31.02			

*Change in "% Correct" from default (constant probability) specification
**Percent of incorrect (default) prediction corrected by equation

Fuente: Elaboración propia.

