



Probabilidad de quiebra empresarial en el sector de construcción del Ecuador: Periodo 2011 – 2020

Probability of business bankruptcy in the construction sector of Ecuador: Period 2011 – 2020

DOI: <https://doi.org/10.17981/econcuc.44.2.2023.Econ.2>

Artículo de Investigación científica y tecnológica.

Fecha de recepción: 30/09/2022

Fecha de devolución: 02/02/2023

Fecha de aceptación: 18/04/2023

Fecha de publicación: 25/04/2023

Iván Felipe Orellana Osorio 

Universidad del Azuay
Cuenca, Azuay (Ecuador)

ivano@uazuay.edu.ec

Luis Gabriel Pinos Luzuriaga 

Universidad del Azuay
Cuenca, Azuay (Ecuador)

lpinos@uazuay.edu.ec

Marco Antonio Reyes Clavijo 

Universidad del Azuay
Cuenca, Azuay (Ecuador)

mreyes@uazuay.edu.ec 

Estefanía del Rocío Cevallos Rodríguez 

Universidad del Azuay
Cuenca, Azuay (Ecuador)

ecevallosr@uazuay.edu.ec

Luis Bernardo Tonon Ordóñez 

Universidad del Azuay
Cuenca, Azuay (Ecuador)

ltonon@uazuay.edu.ec

Para citar este artículo:

Orellana Osorio, I. F., Pinos Luzuriaga, L. G., Reyes Clavijo, M. A., Cevallos Rodríguez, E. de R. & Tonon Ordóñez, L. B. (2023). Probabilidad de quiebra empresarial en el sector de construcción del Ecuador: Periodo 2011-2020. *Económicas CUC*, 44(2), 9–32. DOI: <https://doi.org/10.17981/econcuc.44.2.2023.Econ.2>

JEL: A C1, C5, G1, L6.

Resumen

En las decisiones empresariales se debe determinar cuáles son las variables que explican la probabilidad de su quiebra para en una segunda etapa realizar predicciones sobre las mismas. El objetivo del presente trabajo de investigación es determinar la probabilidad de quiebra de las empresas del sector de la construcción del Ecuador. Para lograr el cometido, se aplicaron el modelo de regresión logística y el modelo Probit, que son modelos de elección discreta binaria. Entre los hallazgos importantes se puede decir que las variables que explican la probabilidad de quiebra empresarial en este sector son el tamaño de la empresa, el nivel de endeudamiento, la liquidez, la rentabilidad y el ingreso neto. Además, se verificó la capacidad predictiva del modelo bajo diferentes métricas como la sensibilidad, la especificidad y posteriormente la curva ROC. En general el modelo Probit da una mejor capacidad predictiva.

Palabras clave: Quiebra; construcción; regresión logística; probit; capacidad predictiva

Abstract

In business decisions, it is necessary to determine which are the variables that explain the probability of bankruptcy in order to make predictions about them in a second stage. The objective of this research work is to determine the probability of failure of companies in the construction sector in Ecuador. In order to achieve the goal, the logistic regression model and the Probit model were applied, which are binary discrete choice models. Among the important findings, it can be said that the variables that explain the probability of business bankruptcy in the sector are the size of the company, the level of indebtedness, liquidity, profitability and net income. In addition, the predictive capacity of the model was verified under different metrics such as sensitivity, specificity and later the ROC curve. In general, the Probit model gives a better predictive capacity of the model.

Keywords: Bankruptcy; construction; logistic regression; probit; predictive capacity

INTRODUCCIÓN

Todas las empresas están expuestas a riesgos financieros y no financieros los cuales pueden condicionar los resultados de sus operaciones. El riesgo se define como la probabilidad de variación en un resultado esperado (Spekman & Davis, 2004), es decir, que representa algo negativo. Sin embargo, en finanzas, cada vez que se asume un riesgo, se está reconociendo que trae consigo una dimensión positiva. Riesgo y rentabilidad son dos aspectos interdependientes en la actividad empresarial: se debe asumir un determinado nivel de riesgo para conseguir una rentabilidad deseada o que la permita esta acción (Solomon & Muntean, 2012).

Existen múltiples factores que afectan la salud financiera de las empresas, entre los cuales, Cueva et al. (2017) mencionan: deficiencia administrativa, cambios estructurales del mercado, impactos en los ciclos económicos y problemas de liquidez. De acuerdo a Martínez, Cazallo, Meñaca y Uribe (2020), la quiebra empresarial es un asunto de importancia económica y es una cuestión de permanente interés para un conjunto amplio de agentes económicos y sociales.

Para Bermeo y Armijos (2021), el desafío al que se enfrentan las empresas en relación a la permanencia a través del tiempo y la capacidad para identificar los factores obliga a controlar permanentemente el riesgo de quiebra. Si no se aplican los correctivos necesarios, esta situación puede ser crítica hasta llegar al cierre de la empresa, y no se afecta únicamente a los propietarios, sino a los distintos grupos de interés como son acreedores, accionistas, trabajadores, incluso el mismo Estado.

Bajo este contexto, Támara y Villegas (2021) aseveran que la quiebra empresarial se considera un evento causante de pérdidas tanto económicas como sociales, y constituye un factor de riesgo para los inversionistas, por lo que es considerada en ocasiones una causa de las crisis internas en la economía. Incluso para autores como Kliestik, Misankova, Valaskova y Svabova (2018), la bancarrota viola los derechos humanos y el principio de justicia, dos criterios que a menudo se utilizan para examinar si las acciones son éticas. Por esta razón, el análisis de riesgo financiero se convierte en una herramienta importante para evitar el fracaso empresarial.

Existen diversos modelos y herramientas estadísticas que buscan predecir el riesgo financiero. De acuerdo a Dupleix (2021), el foco inicial del estudio del fracaso empresarial se colocó en la identificación y el análisis de sus causas, sin embargo, esto resultó ser insuficiente para conocer el fenómeno en profundidad. Los objetivos de esta investigación son estimar y pronosticar la probabilidad de quiebra empresarial en el sector de la construcción del Ecuador (CIU-F), por medio de los modelos econométricos de regresión logística y Probit.

El estudio se encuentra dividido por secciones. En la segunda sección se revisa la literatura y marco teórico, en donde se explican conceptos generales sobre el riesgo de quiebra empresarial, además se mencionan las principales investigaciones relacionadas al tema. En la tercera sección se explica la metodología aplicada, además de una breve descripción de los datos utilizados. En la cuarta sección se presentan los resultados; y finalmente se exponen las principales conclusiones y discusiones del estudio.

ESTADO DEL ARTE

El riesgo financiero se define como la variabilidad adicional de los flujos de efectivo netos del patrimonio de los propietarios que resultan de las obligaciones financieras fijas asociadas con el financiamiento de deuda y el arrendamiento de efectivo (Krishnasami, 2012).

Entre los tipos de riesgo financiero se encuentra el riesgo de bancarrota o quiebra la cual se refiere a una situación de insolvencia en la que una persona natural o física no puede afrontar o cubrir sus pasivos mediante sus recursos económicos disponibles, valor reducido de los activos o escasez del flujo de caja, o la empresa está en quiebra de acuerdo con la ley, por lo tanto descontinúa sus operaciones (Ahn, Cho y Kim, 2000; Wu, 2010; Romero, Melgarejo y Vera-Colina, 2015; Cueva et al., 2017). En la investigación de Cortes, Saavedra y Palacios (2021) se define el fracaso empresarial como insolvencia técnica o falta de liquidez, situación que conlleva la quiebra de la empresa.

FitzPatrick (1932) analizó el fracaso empresarial, quien aseveró que el desarrollo de indicadores seleccionados difiere en grupos de empresas insolventes y solventes antes de que ocurran dificultades financieras. Posteriormente, en una etapa predictiva, Beaver (1966) propone la predicción del fracaso empresarial por medio de un análisis univariado. Altman (1968) y Altman, Haldeman y Narayanan (1977) predicen la quiebra empresarial a través del Análisis Discriminante Múltiple (ADM), al igual que Deakin (1972).

Desde 1980 se ha incrementado el interés por los modelos Logit y Probit debido al fácil acceso de datos microeconómicos sobre la forma de actuar de agentes económicos, ya que permiten explicar cómo su comportamiento afecta otras variables del mercado (Ariza Dau, Acosta Rueda y Altamar, 2016). Las limitaciones del análisis discriminante crearon espacio para el desarrollo del modelo Logit (Singh & Mishra, 2016). Ohlson (1980) introdujo un modelo Logit en la literatura de predicción de quiebra, con supuestos distintos a los modelos de puntuación Z propuestos por Altman (1968); en el modelo intervienen 9 variables (financieras y no financieras), en donde se obtiene la probabilidad de fracaso de una empresa. Zmijweski (1984) aplicó la técnica Probit utilizando datos de 40 empresas estadounidenses en quiebra y 800 no en quiebra durante el período 1972-1978.

Mittal y Lavina (2018) determinaron el estrés financiero en la industria inmobiliaria y de la construcción en la India a través de la aplicación de modelos de probabilidad lineal, Probit y Logit en con el fin de identificar el predictor determinante. Svabova, Michalkova, Durica y Nica (2020), basándose en el análisis discriminante y la regresión logística, hicieron la predicción del fracaso empresarial para pequeñas y medianas empresas eslovacas. Ogachi, Ndege, Gaturu y Zoltan (2020) realizaron un estudio que se basó en la construcción de un modelo integral incluyendo el análisis logístico, para predecir la quiebra en empresas que cotizan en bolsa en Kenia. También, Kücher, Mayr, Mitter, Duller y Feldbauer-Durstmüller (2020) realizaron varios análisis de regresión logística binaria para determinar la edad y mortalidad empresarial de pequeñas y medianas empresas de la Unión Europea.

En el ámbito regional, **Cruz, Gavira y García (2017)** analizaron los modelos Poisson y Logístico en la asignación de probabilidades de incumplimiento a empresas mineras mexicanas. **Pérez, González y Lopera (2013)** analizaron la fragilidad empresarial en Colombia a través de los modelos Logit y Probit. **Romero (2013)** estudió las variables financieras determinantes del fracaso empresarial para la pequeña y mediana empresa en Colombia bajo el modelo Logit. **Bravo y Pinto (2008)** desarrollaron un trabajo de predicción de insolvencias en microempresas chilenas a través de la comparación de modelos de inteligencia artificial y de la aplicación de un modelo de regresión logística.

En el ámbito ecuatoriano, **Cueva et al. (2017)** analizaron la fragilidad financiera de las empresas a través de la estimación de un modelo probabilístico Logit y Probit. **Bermúdez y Bravo (2019)**, a través de modelos Logit, Probit y Complementary log regression (Cloglog), estimaron los determinantes que se relacionan con la probabilidad de cierre empresarial en las MIPYMES del Ecuador durante el periodo 2007-2016. **Bermeo y Armijos (2021)** aplicaron el Modelo Z2 Altman en la predicción de quiebra en las empresas de construcción de edificios residenciales del Azuay.

METODOLOGÍA

El tipo de investigación es cuantitativo con un alcance explicativo. La ventana temporal del análisis fue el periodo 2011-2020, debido a que los balances financieros se encuentran disponibles desde esa fecha, tanto por exigencia de las NIIF como por disponibilidad de información en la **Superintendencia de Compañías, Valores y Seguros-Supercias (2020)**. Se trabajó con 39 116 observaciones (3 012 empresas anuales en promedio). (**Tabla 1**).

TABLA 1.
Clasificación del sector de construcción del Ecuador.

CIU	Descripción	Observaciones	Empresas
F41	Construcción de edificios	18 931	4 400
F42	Obras de ingeniería civil	13 812	3 334
F43	Actividades especializadas de la construcción	6 373	1 319

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

En este trabajo de investigación se aplicaron dos modelos para predecir la probabilidad de quiebra empresarial en el sector de la construcción: regresión Logística y Probit. A estos modelos se les denominan modelos probabilísticos, porque se trata de estimar la probabilidad de ocurrencia del evento, que en este caso es la probabilidad de quiebra empresarial.

Estos modelos clasifican un resultado binario categórico, siendo la variable de respuesta igual a 1 si la empresa está en una situación de quiebra y 0 si no lo está. En esta investigación se consideraron como empresas quebradas aquellas que cumplen dos condiciones: patrimonio negativo y pérdida del ejercicio en el último periodo.

La estimación se la realiza a través del método de máxima verosimilitud, ya que al estimar la ecuación vía mínimos cuadrados ordinarios se incurre en algunos problemas, entre ellos los más importantes, de acuerdo a **Gujarati y Porter (2010)**, son: 1) la no normalidad y heterocedasticidad de los errores, 2) la posibilidad que la probabilidad estimada \hat{Y}_i (variable de salida o dependiente) tome valores mayores a 1 o menores a 0 y 3 supone que $P_i = E(Y = 1/ X_i)$ aumenta linealmente con X (variable independiente), es decir, que el efecto marginal de X se mantiene constante. En este sentido se necesita un modelo que responda a las siguientes características: 1) a medida que aumenta X , la probabilidad de ocurrencia del acontecimiento, $P_i = E(Y = 1/ X_i)$ también aumenta pero que no se salga del intervalo entre cero y uno, y 2) relación no lineal entre P_i y X , es decir, a medida que X se reduce, se acerca a 0 con tasas cada vez más lentas y al contrario, a medida que X aumenta, se acerca a 1 con tasas cada vez más lentas.

Modelo de regresión logística

Este modelo propone la primera solución a los problemas planteados bajo el método de mínimos cuadrados ordinarios, este modelo utiliza una función logística acumulativa, mediante el cual se propone calcular la probabilidad de ocurrencia de quiebra empresarial mediante la siguiente expresión (1):

$$P_i = \frac{1}{1+e^{-(\beta_0+\beta_1X_1+\beta_2X_2+\beta_3X_3+\dots+\beta_nX_n)}} \quad (1)$$

Se puede expresar también de la siguiente manera (2):

$$P_i = \frac{1}{1+e^{-(z_i)}} = \frac{e^z}{1+e^z} \quad (2)$$

Donde:

P_i = Probabilidad de quiebra empresarial.

$\beta_0, \beta_1, \beta_2, \beta_3, \dots, \beta_n$ = Los parámetros a estimar.

$X_1, X_2, X_3, \dots, \beta_n$ = Las variables independientes
(pueden ser cualitativas o cuantitativas).

$$Z = \beta_0 + \beta_1X_1 + \beta_2X_2 + \beta_3X_3 + \dots + \beta_nX_n$$

Si P_i es Probabilidad de quiebra empresarial, entonces $1 - P_i$ es la probabilidad de no quiebra empresarial, especificado de la siguiente manera (3)(4):

$$1 - P_i = 1 - \frac{e^z}{1+e^z} \quad (3)$$

$$1 - P_i = \frac{1}{1 + e^{z_i}} \quad (4)$$

En este caso, la división entre P_i y $1 - P_i$ es la llamada razón de probabilidades en favor de que la empresa quiebre y está expresada de la siguiente manera (5):

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

Si se aplica un logaritmo natural a la expresión anterior se obtiene (6):

$$L_i = \ln\left(\frac{P_i}{1 - P_i}\right) = Z_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n \quad (6)$$

Donde L_i es el logaritmo de la razón de probabilidades con estas características:

- A pesar que las probabilidades estén entre cero y uno, los Logit no están acotados de esta forma.
- L es lineal pero las probabilidades no lo son.

Si el Logit es positivo significa que, al aumentar el valor de los regresores, aumenta la probabilidad que la regresada sea igual a 1, mientras que, si es negativo al aumentar el valor de los regresores, disminuye la probabilidad que la regresada sea igual a 1.

Modelo Probit

El modelo Probit utiliza una función de distribución acumulada normal, en este modelo, el hecho que una empresa esté en quiebra o no depende de un índice de conveniencia no observable o variable latente (I_i), determinada por una o más variables explicativas (X), de manera que entre mayor sea el I_i , mayor será la probabilidad que la empresa quiebre, en este sentido $I_i = \beta_0 + \beta_1 X_i$, por tanto, si $Y = 1$ es una empresa que está en quiebra, es razonable suponer que cada empresa tiene un nivel crítico o umbral del índice que lo llamaremos I_i^* , de manera que si $I_i > I_i^*$ la empresa estará en una situación de quiebra, de lo contrario no estará en esta situación. Si ambos índices no son observables, pero suponemos que se distribuyen normalmente, los resultados quedarán expresados de la siguiente manera (7):

$$\begin{aligned} P_i &= P(Y = 1/X) = P(I_i > I_i^*) = P(I_i^* \leq I_i) \\ &= P(Z_i \leq \beta_0 + \beta_1 X_i) = F(\beta_0 + \beta_1 X_i) \end{aligned} \quad (7)$$

Donde Z es la variable normal estandarizada.

La función de distribución está expresada de la siguiente manera (8):

$$F(I_i) = \frac{1}{\sqrt{2\pi}} \int_{-\alpha}^{\beta_0 + \beta_1 X_i} e^{-z^2/2} dz \quad (8)$$

Como se ha mencionado, P es la probabilidad que quiebre la empresa, gráficamente esta probabilidad estará medida por el área bajo la curva normal entre $-\alpha$ y $\beta_0 + \beta_1 X_i$. Adicionalmente es necesario recalcar que la principal diferencia entre el modelo de regresión logística y el modelo Probit radica en los extremos de la distribución, en el primero las colas de la distribución son más anchas, por lo que se podría decir que en este se puede recoger mejor los valores en los extremos.

Para obtener los modelos propuestos Logit y Probit se tomaron como referencia las variables independientes propuestas por el modelo de **Ohlson (1980)**, las cuales se describen a continuación:

- X1 (Tamaño) = Logaritmo (activos totales/índice del nivel de precios).
- X2 = Pasivos Totales/Activos Totales.
- X3 = Capital de Trabajo/Activos Totales.
- X4 = Pasivo corriente/Activo corriente.
- X5 = Dummy de solvencia: 1 si los pasivos totales exceden los activos totales.
- X6 = Utilidad neta/Activos Totales.
- X7 = Resultado operacional/Total de las obligaciones
- X8 = Dummy de rentabilidad: 1 si el ingreso neto fue negativo en 2 últimos años.
- X9 = Ingreso Neto t – Ingreso Neto t-1/|Ingreso Netot|+ |Ingreso Netot-1|.

Los signos esperados de cada variable con relación a la variable dependiente se muestran en la **Tabla 2**, a continuación:

TABLA 2.
Variables esperadas del modelo de Ohlson.

Variable	Signo esperado
X1	Negativo
X2	Positivo
X3	Negativo
X4	Positivo
X5	positivo
X6	Negativo
X7	Negativo
X8	Positivo
X9	Negativo

Fuente: Elaboración propia.

Para evaluar la capacidad de predicción del modelo se recurrió a la matriz de confusión, en donde se registra el error y el acierto de clasificación del modelo, esta es una matriz 4×4 en donde se puede visualizar el acierto positivo y negativo, así como el falso positivo y negativo. A partir de la **Tabla 3** se pueden construir métricas como la precisión, la sensibilidad y la especificidad.

TABLA 3.
Matriz de confusión.

	1	0
1	n_{11}	n_{12}
0	n_{21}	n_{22}

Fuente: Elaboración propia.

Donde

n_{11}	=	Acierto Positivo.
n_{12}	=	Falso Positivo.
n_{21}	=	Falso Negativo.
n_{22}	=	Acierto Negativo.

Se puede calcular la tasa de error total de la siguiente manera (9):

$$\text{Tasa de error total} = \frac{n_{12} + n_{21}}{n_{11} + n_{12} + n_{21} + n_{22}} \quad (9)$$

Adicionalmente se puede decir que 1- la tasa global de error es la tasa de precisión del modelo. Además, se puede medir la tasa de error con respecto a las clases individuales.

$$\text{tasa de error de la clase 1} = \frac{n_{12}}{n_{11} + n_{12}} \quad (10)$$

$$\text{tasa de error de la clase 0} = \frac{n_{21}}{n_{21} + n_{22}} \quad (11)$$

Para entender el tradeoff entre error de la clase 1 y 0, se tiene que prestar atención al punto de corte para la clasificación de las observaciones. Evidentemente mientras más pequeño sea el punto de corte más observaciones serán clasificadas en la clase 1, por lo que el error será el error de esta clase y mayor será el error de la clase 0.

Finalmente se puede decir que existen otras métricas para evaluar el rendimiento del modelo a partir de la tasa de error total, tasa de error de la clase 1 y 0, y estas son la sensibilidad y la especificidad. La Sensibilidad, es el porcentaje de

clasificación correcta de los 1 cuando realmente son 1, matemáticamente es igual a $1 - \text{tasa de error de la clase 1}$. La especificidad es el porcentaje de clasificación correcta de los 0 cuando son 0, matemáticamente es igual a $1 - \text{tasa de error de la clase 1}$.

La curva ROC es una alternativa gráfica que nos muestra el tradeoff entre la habilidad de clasificar correctamente la clase 1 y 0, gráficamente lo podemos evaluar con el área bajo la curva, específicamente, a mayor área bajo la curva ROC, mejor capacidad de predicción tendrá el modelo. En el eje vertical está la sensibilidad del clasificador y en el eje horizontal está el error de la clase 0 ($1 - \text{especificidad}$).

RESULTADOS

Análisis estadístico del modelo Logit

Una vez evaluados signos de los coeficientes y su significancia individual, se procedió a estimar el mejor modelo Logit, el mismo que se observa en la **Tabla 4**.

TABLA 4.
Modelo Logit.

glm(formula = vd ~ x1 + x2 + x3 + x8 + x9, family = binomial (link = "logit"), data = logitconst2)				
Deviance Residuals:				
Min	1Q	Median	3Q	Max
-8.4904	-0.3612	-0.2585	-0.1829	3.3140
Coefficients:				
	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	2.91396	0.06902	-42.22	<2e-16***
x1	-0.32718	0.01986	-16.48	<2e-16***
x2	0.64785	0.03541	18.30	<2e-16***
x3	0.52876	0.03581	14.77	<2e-16***
x8	2.16487	0.04710	45.96	<2e-16***
x9	-0.96441	0.03539	-27.25	<2e-16***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
(Dispersion parameter for binomial family taken to be 1)				
Null deviance: 20846 on 39115 degrees of freedom				
Residual deviance: 15583 on 39110 degrees of freedom (1 observation deleted due to missingness)				
AIC: 15595				

Fuente: Elaboración propia.

Se dejaron en el modelo las variables que no tienen una multicolinealidad severa, y, por tanto, fueron estadísticamente significativas al nivel de significancia de 0.05. Las variables tamaño de la empresa y la expectativa de ingreso neto tienen una

relación negativa con la probabilidad de insolvencia, sin embargo, las variables nivel de endeudamiento, nivel de liquidez de la empresa y rentabilidad (variable dummy, en donde 1 es ingreso neto negativo en los dos últimos años y 0 caso contrario), tuvieron una relación positiva con la probabilidad de insolvencia empresarial.

Si se aplica el antilogaritmo a los coeficientes estimados se obtiene el odd Ratio; se puede ver que la variable x8 (Dummy de rentabilidad) es la que tiene la mayor razón de probabilidades igual al 8.71, lo que quiere decir que, si el ingreso neto de los dos últimos años fue negativo, la empresa es 8.71 veces más propensa a quebrar que una que no tuvo ingreso neto negativo en los dos últimos años. Las razones de probabilidad de las demás variables se muestran en la **Tabla 5**:

TABLA 5.
Razones de probabilidad del modelo de Altman (1968).

Variable	Razón de Probabilidad
X1	0.7209
X2	1.9114
X3	1.6968
X8	8.7134
X9	0.3812

Fuente: Elaboración propia.

Los resultados de las estimaciones de las probabilidades de quiebra empresarial del modelo de regresión logística se muestran en la **Figura 1**, en donde se puede observar que las empresas están distribuidas asimétricamente ya que gran parte de ellas están concentradas en bajas probabilidades. El modelo puede estar influenciado por la clase que tiene mayor peso (empresas que no están en una situación de quiebra), esta situación se la puede resolver con remuestreo con reemplazo, con datos sintéticos o ajustando la clase con mayor número de observaciones a la de menor; también, down samplly, upsamplly, o se puede hacer una mezcla de las dos.




Figura 1. Estimaciones de probabilidades del modelo Logit.
Fuente: Elaboración propia.

Ahora se procede a probar la capacidad de predecir el modelo de regresión logística estimado, para lo cual se utilizará la curva ROC. El punto de corte óptimo es de 0.0750, el mismo que se obtiene al maximizar la sensibilidad y la especificidad. Gráficamente, es el punto de corte entre la sensibilidad y la especificidad (Figura 2):




Figura 2. Capacidad de predicción del modelo Logit
Fuente: Elaboración propia.

La curva ROC muestra que el área bajo la curva es de 0.861, los valores de la sensibilidad y especificidad son de 78.4% y 78.5% respectivamente (Figura 3).




Figura 3. Curva ROC del modelo Logit.
Fuente: Elaboración propia.

Análisis estadísticos del modelo Probit

Una vez evaluados signos de los coeficientes y su significancia individual, se procedió a estimar el mejor modelo Probit, el mismo que se observa en la **Tabla 6**.

TABLA 6.
Modelo Probit.

call: glm(formula = vd ~ x1 + x2 + x3 + x8 + x9,
family = binomial (link = "probit"), data = logitconst2)

Deviance Residuals:

Min	1Q	Median	3Q	Max
-8.4904	-0.3403	-0.2396	-0.1509	3.5046

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-1.83305	0.03725	-49.21	<2e-16***
x1	-0.14057	0.01027	-13.69	<2e-16***
x2	0.45740	0.02098	21.80	<2e-16***
x3	0.31122	0.02131	14.61	<2e-16***
x8	1.14992	0.02621	43.87	<2e-16***
x9	-0.51043	0.01801	-28.34	<2e-16***

 Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
 (Dispersion parameter for binomial family taken to be 1)
 Null deviance: 20846 on 39115 degrees of freedom
 Residual deviance: 14953 on 39110 degrees of freedom
 (1 observation deleted due to missingness)
 AIC: 14965
 Number of Fisher Scoring iterations: 25

Fuente: Elaboración propia.

Como en el modelo Logit, las variables X1, X2, X3, X8 y X9 son significativas; los valores estimados de los coeficientes no son directamente comparables con los valores del modelo de regresión logística. Los valores del modelo Probit se muestran en la **Figura 4**:




Figura 4. Estimaciones de probabilidades del modelo Probit.
Fuente: Elaboración propia.

Adicionalmente, para evaluar la capacidad de proyección del modelo se elaboró la curva ROC, para la cual se determinó un punto de corte óptimo de 0.0728 que corresponde al punto en donde la sensibilidad y la especificidad se cruzan (Figura 5).

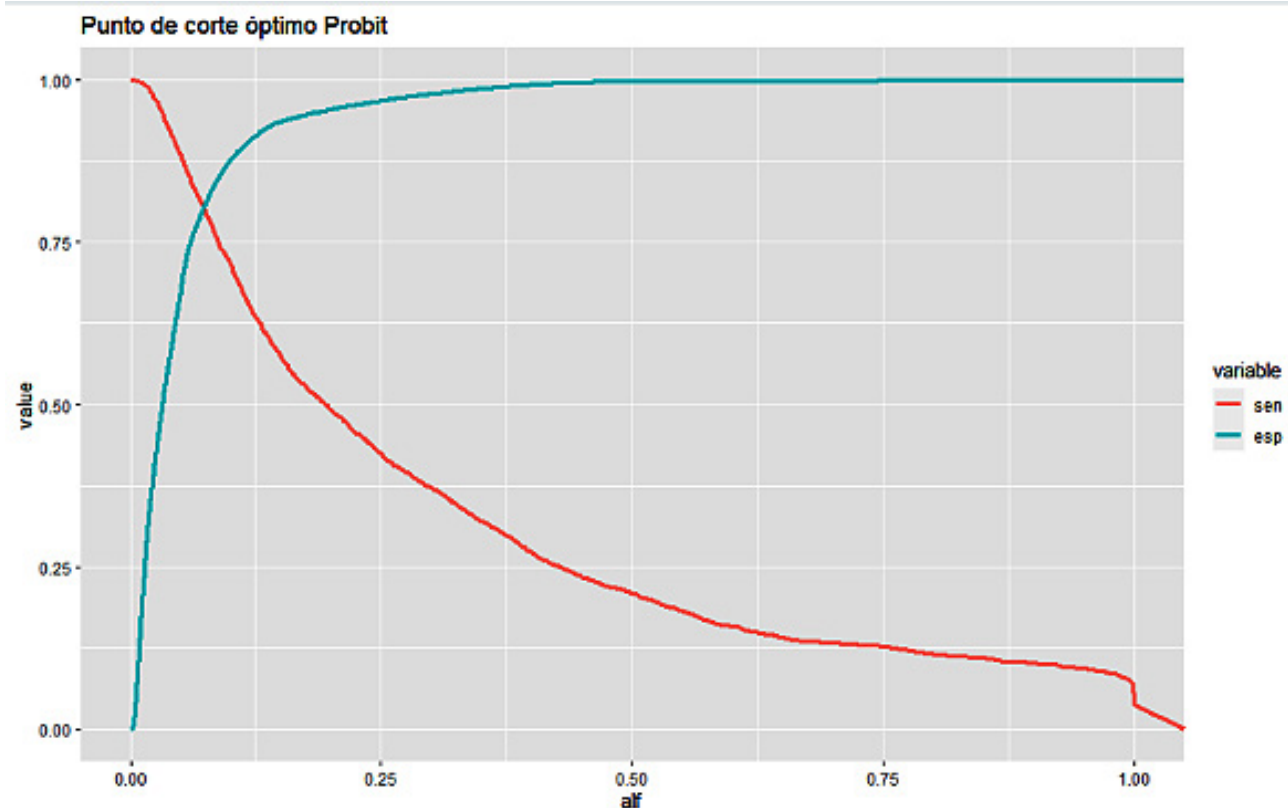


Figura 5. Capacidad de predicción del modelo probit.
Fuente: Elaboración propia.

Ahora se grafica la curva ROC, los valores de la sensibilidad y especificidad son un 77.7% y 83.1% respectivamente en el modelo Probit (Figura 6).




Figura 6. Curva ROC del modelo Probit.
Fuente: Elaboración propia.

Resultados de la aplicación de los modelos

En la **Figura 7** se observa los resultados de los modelos Logit y Probit. La probabilidad de quiebra más alta se presenta en 2016 (Logit 8.32% y Probit 7.99%), estos valores corresponden a un punto más alto que el valor de corte de ambos modelos, por lo que caen en la zona de quiebra. La probabilidad de quiebra más baja se presentó en el año 2019 (Logit 6.48% y Probit 6.20%), estos valores corresponden a un punto bajo que el valor de corte de ambos modelos, por lo que caen en la zona de no quiebra.




Figura 7. Probabilidad de quiebra anual – Logit y Probit.
Fuente: **Supercias (2020)**.

En la **Figura 8** se desagrega el análisis de acuerdo a la clasificación de las empresas en los modelos (quiebra = 1; no quiebra = 0) del modelo Logit. Las empresas no quebradas poseen niveles de riesgo que van desde 5.38% hasta 6.18%, mientras que las que están en situación de quiebra desde 24.40% hasta 29.38%.




Figura 8. Probabilidad de insolvencia de empresas clasificadas como quebradas y no quebradas – modelo Logit.
Fuente: **Supercias (2020)**.

En la **Figura 9** se desagrega el análisis de acuerdo a la clasificación de las empresas en los modelos (quiebra = 1; no quiebra = 0) del modelo Probit. Las empresas no quebradas poseen niveles de riesgo que van desde 4.80% hasta 6.10%, mientras que las quebradas desde 25.49% hasta 36.19%.

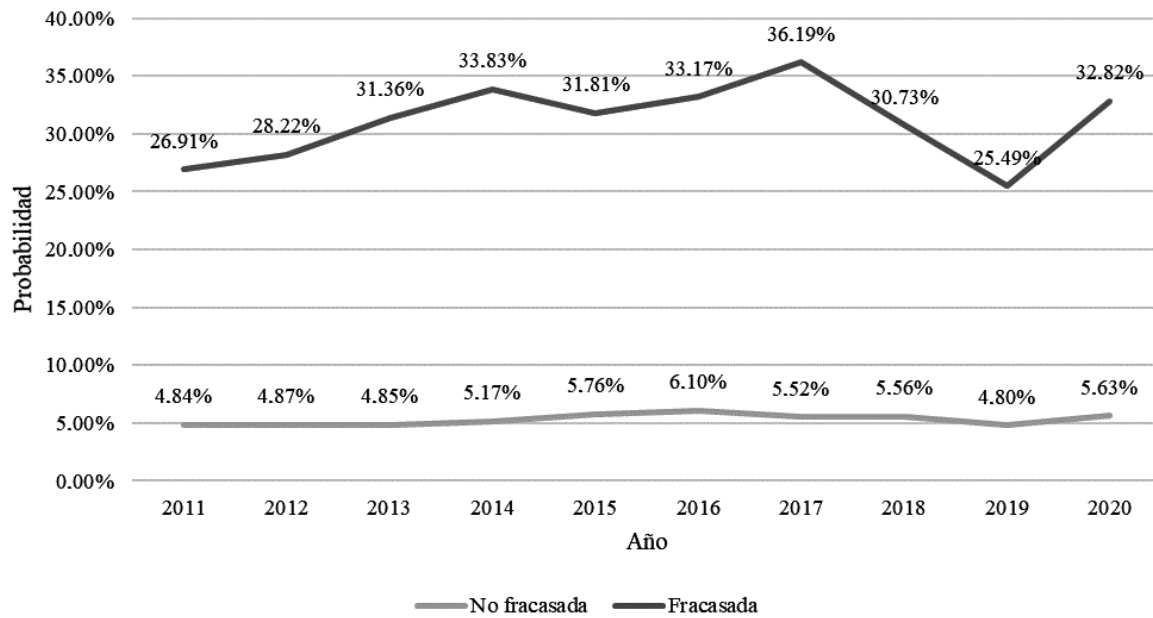


Figura 9. Probabilidad de insolvencia de empresas clasificadas como quebradas y no quebradas – modelo Probit.
Fuente: **Supercias (2020)**.

Como se observa en la **Figura 10** y **Figura 11**, las microempresas son más propensas a quebrar, por el contrario, las empresas grandes son menos riesgosas, situación que coincide en los modelos Logit y Probit.




Figura 10. Probabilidad de quiebra por tamaño empresarial del sector C23-modelo Logit.
Fuente: **Supercias (2020)**.




Figura 11. Probabilidad de quiebra por tamaño empresarial del sector C23-modelo Probit.
Fuente: **Supercias (2020)**.

En la **Figura 12** se muestra que las empresas del subsector F41 tienen una mayor probabilidad de quiebra; sin embargo, las diferencias no son significativas.




Figura 12. Probabilidad quiebra en los subsectores F41, F42 y F43.
Fuente: **Supercias (2020)**.

Al analizar las 3 provincias con mayor nivel de participación de empresas en el sector, se determinó que las empresas de Guayas poseen una menor probabilidad de quiebra (**Figura 13**).

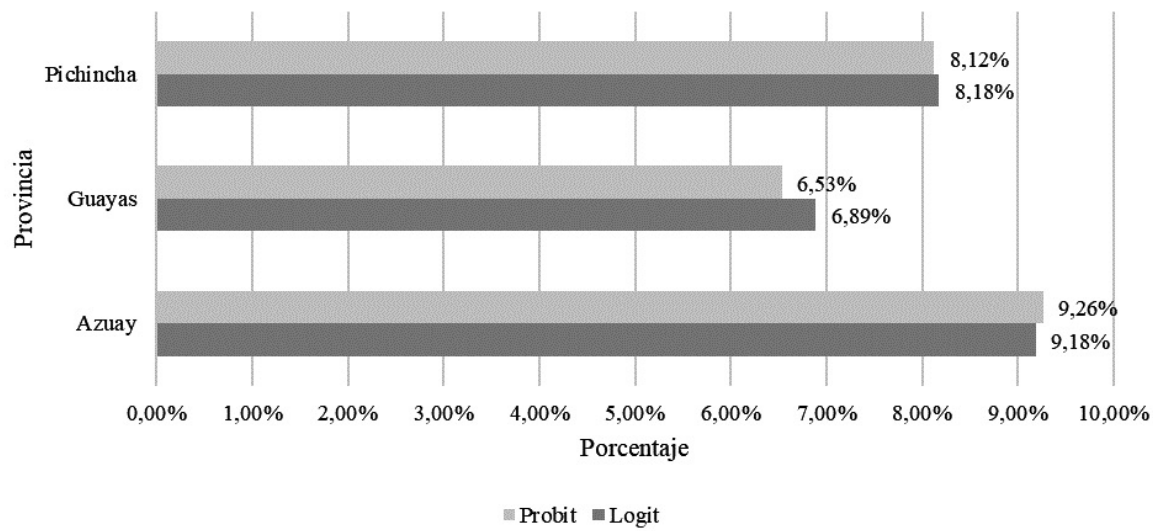


Figura 13. Probabilidad de quiebra de empresas del sector construcción por provincia.
Fuente: **Supercias (2020)**.

DISCUSIÓN DE LOS RESULTADOS

La quiebra generalmente se desencadena por incumplimiento del servicio de la deuda, y es menos probable que esto ocurra si la empresa tiene acceso a financiamiento interno o externo. Una empresa con un flujo de caja saludable tiene un acceso relativamente fácil a la financiación interna (**Lennox, 1999**), lo cual significa que este tipo de empresa tiene una menor probabilidad de quebrar. También el autor asevera que la rentabilidad, el apalancamiento y flujo de caja tienen efectos importantes sobre la probabilidad de quiebra. De acuerdo a **Rodríguez, Maté y López (2020)**, también una de las vías de propagación del fracaso empresarial es la proximidad geográfica entre empresas.

El rol del administrador juega un papel importante, al disponer de una mayor información en el proceso de toma de decisiones que repercuten en el éxito o fracaso de la empresa. En el caso ecuatoriano, **Cueva et al. (2017)** indican que un aumento de la liquidez indica mayor fragilidad, ya que las empresas poseen recursos ociosos. Además de lo mencionado, es importante analizar los efectos del tamaño de la empresa, el sector industrial y el ciclo económico en la probabilidad de quiebra.

En esta investigación se utilizó el marco referencial de **Ohlson (1980)**, el cual ocupa 9 variables para estimar la probabilidad de quiebra de las empresas. Para el sector de la construcción, 5 variables resultaron ser estadísticamente significativas (X1, X2, X3, X8 y X9), de las cuales todas tienen relación con el modelo de **Ohlson (1980)** en cuanto a los signos, excepto X3; esto significa que en el modelo propuesto, a mayor proporción de capital de trabajo sobre la inversión total, mayor es la exposición a riesgo de quiebra y lógicamente, mayor será la probabilidad de quiebra.

En cuanto a la variable X1, según **Zambrano, Sánchez y Correa (2021)**, el índice de fracaso de las empresas pequeñas es más elevado en comparación con las de gran tamaño, debido a su falta de experiencia y conocimiento del mercado, esta conclusión la podemos ratificar en la estimación de los modelos obtenidos en la presente investigación.

En absolutamente todos los estudios la variable X2 tiene una influencia positiva en la probabilidad de quiebra de las empresas independientemente del sector analizado; esta afirmación la sustentan autores como [Krishnasami \(2012\)](#); [Ahn et al., \(2000\)](#); [Wu \(2010\)](#); [Romero et al. \(2015\)](#); [Cueva et al. \(2017\)](#); [Altman \(1968\)](#) y [Olhson \(1980\)](#), entre otros.

El uso de la deuda en las empresas eleva su probabilidad de insolvencia, pero al mismo tiempo se obtienen beneficios con su uso como los escudos fiscales. La variable X8 nos muestra que la posibilidad de quiebra se eleva 8,71 veces si la empresa tiene un ingreso neto negativo en los dos últimos años, conclusión con la que concuerda [Olhson \(1980\)](#), si bien con una diferente magnitud del coeficiente estimado, pero en el mismo signo. Finalmente, la variable X9, tiene una relación inversa con la probabilidad de insolvencia como era de esperarse debido a variaciones positivas en las ventas o ingresos de las empresas.

Cualitativamente los modelos Logit y Probit son similares, pues es posible hallar los coeficientes del modelo Logit a partir del Probit y viceversa ([Ariza Dau et al., 2016](#)). En la literatura suele emplearse en su mayoría el modelo Probit porque es posible ajustar el error de la variable dependiente en modelos de autoselección debido a que estos modelos presentan una distribución normal.

El modelo Logit por otra parte, presenta varias ventajas: cuando todas las variables independientes de un modelo son discretas se facilita la comprensión de los coeficientes y cuando presenta muestras muy grandes se tienen en cuenta datos que la distribución normal de un modelo Probit clasificaría como inusuales ([Ariza Dau et al., 2016](#)). Se han realizado comparaciones entre los modelos Logit, Probit y análisis discriminante.

Se encontró que los modelos Probit y Logit funcionan mejor que el análisis discriminante ([Lennox, 1999](#)). [Lin \(2009\)](#) compara los modelos de análisis discriminante múltiple, Probit, Logit y redes neuronales; los tres últimos logran una mayor precisión de predicción, sin embargo, el que más se destaca es el modelo Probit. La importancia de estos modelos radica en la capacidad de predicción de problemas a futuro. De acuerdo a [Navarrete \(2022\)](#), una organización inteligente debería crear modelos para afrontar los cambios y evoluciones internas que son un reflejo de las necesidades externas.

CONCLUSIONES

Este trabajo presentó un modelo de regresión logística y un modelo Probit, con el fin de estimar la probabilidad de quiebra de las empresas en el sector de la construcción que reportaron sus estados financieros a la Superintendencia de Compañías Valores y Seguros para el período 2011-2020, para lo cual se utilizaron diferentes indicadores financieros, los cuales fueron propuestos por [Ohlson \(1980\)](#).

Evidentemente, no todas las variables aplicadas resultaron significativas entre estas están: pasivo corriente/activo corriente, la variable dummy de solvencia, utilidad neta /activos totales y resultado operacional/total de obligaciones.

Las variables que resultaron siendo estadísticamente significativas son: el tamaño de la empresa, pasivos totales/activos totales, capital de trabajo/activos totales, la variable dummy de rentabilidad y la variación del ingreso neto.

En ambas metodologías utilizadas el año que presenta empresas con mayor nivel de probabilidad de fracaso es el 2016, por el contrario, en el año 2019 existe una menor probabilidad. Las empresas clasificadas como fracasadas presentan probabilidades de fracaso que van desde 25.49% a 36.19%, y las empresas no clasificadas como fracasadas probabilidades desde 4.87% a 6,10%. Claramente, las empresas grandes tienen una menor probabilidad de fracaso.

Para la evaluación del poder predictivo del modelo, se utilizaron diferentes métricas como la sensibilidad, especificidad, recall y gráficamente la curva ROC; se comprobó que el modelo Probit tiene una mejor capacidad predictiva.

Finalmente se puede decir que existen muchas técnicas que podrían mejorar la capacidad predictiva del modelo, por ejemplo, la regresión logística utilizando regularización, con una adecuada estrategia de remuestreo. Adicionalmente se puede trabajar este tipo de datos con Naive Bayes, árboles de clasificación, o modelos aditivos generalizados, o análisis discriminante.

RECOMENDACIONES

Se recomienda medir el impacto de los modelos propuestos en periodos posteriores con una muestra de empresas, para de esta manera conocer la capacidad de predicción.

DECLARACIÓN DE AUTORÍA

Orellana Osorio: Conceptualización, análisis formal, escritura-revisión y edición, supervisión, administración de proyectos.

Pinos Luzuriaga: Metodología, validación, análisis formal, escritura-revisión y edición, visualización.

Reyes Clavijo: Conceptualización, metodología, análisis formal, investigación, escritura-borrador original, escritura - revisión y edición, visualización.

Cevallos Rodríguez: Investigación, escritura-borrador original, escritura-revisión y edición.

Tonon Ordóñez: Validación, investigación, escritura-revisión y edición.

FINANCIACIÓN

El presente producto de investigación deriva del proyecto titulado “Revisión y Análisis de los Modelos Estocásticos de Equilibrio General”.

DECLARACIÓN DE CONFLICTO DE INTERESES

Para los autores este trabajo no representa ningún conflicto de interés

RECONOCIMIENTOS Y AGRADECIMIENTOS

Los autores agradecen a la Universidad del Azuay, en Cuenca (Ecuador).

REFERENCIAS

- Ahn, B. S., Cho, S. S. & Kim, C. Y. (2000). Integrated methodology of rough set theory and artificial neural network for business failure prediction. *Expert Systems with Applications*, 18(2), 65–74. [https://doi.org/10.1016/S0957-4174\(99\)00053-6](https://doi.org/10.1016/S0957-4174(99)00053-6)
- Altman, E. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609. <https://doi.org/10.2307/2978933>
- Altman, E., Haldeman, R. & Narayanan, P. (1977). ZETATM analysis A new model to identify bankruptcy risk of corporations. *Journal of Banking and Finance*, 1(1), 29–54. [https://doi.org/10.1016/0378-4266\(77\)90017-6](https://doi.org/10.1016/0378-4266(77)90017-6)
- Ariza Dau, M., Acosta Rueda, K. y Altamar, L. (2016). Aplicación de los Modelos de Respuesta Binaria a los Determinantes de la Demanda de Postgrado en Colombia. *Escenarios*, 14(1), 7–18. <https://doi.org/10.15665/esc.v14i1.874>
- Beaver, W. (1966). Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, 4, 71–111. <https://doi.org/10.2307/2490171>
- Bermeo, D. 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*, 33, 48–63. <https://doi.org/10.25097/rep.n33.2021.03>
- Bermúdez, N. y Bravo, A. (2019). Modelo Predictivo de los Determinantes del Cierre Empresarial de las MIPYMES en el Ecuador Período 2007-2016. *X - Pedientes Económicos*, 3(5), 78–93. Disponible en https://ojs.supercias.gob.ec/index.php/X-pedientes_Economicos/article/view/32
- Bravo, F. y Pinto, C. (2008). Modelos predictivos de la probabilidad de insolvencia en microempresas chilenas. *Contaduría Universidad de Antioquia*, (53), 13–52. <https://doi.org/10.17533/udea.rc.2175>
- Cortes, M., Saavedra, M. & Palacios, P. (2021). Análisis del fracaso de las MiPyME franquiciantes en México. Un crecimiento cuestionable del sector. *Revista Perspectiva Empresarial*, 7(2), 36–52. <https://doi.org/10.16967/23898186.651>
- Cruz, S., Gavira, N. & 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. <http://dx.doi.org/10.21919/remef.v12i1.9>
- Cueva, D. F., Cortes, S., Tapia, R., Tabi, W., Torres, J., Maza, C., Uyaguari, K. y González, M. (2017, junio). Fragilidad Financiera de las Empresas - Estimación de un Modelo probabilístico LOGIT y PROBIT: Caso Ecuatoriano. Conferencia presentada en la *XII Conferencia Ibérica de Sistemas y Tecnologías de la Información*, CISTI, Lisbon, Portugal. <https://doi.org/10.23919/CISTI.2017.7975927>

- Deakin, E. (1972). Research Reports A Discriminant Analysis of Predictors of Business Failure. *Journal of Accountin Research*, 10(1), 167–179. <https://doi.org/10.2307/2490225>
- Dupleix, M. (2021). La teoría efectual y el fracaso empresarial. *Innovar*, 31(81), 139–154. <https://doi.org/10.15446/innovar.v31n81.95581>
- FitzPatrick, P. (1932). Average Ratios of Twenty Representative Industrial Failures *. *The Certified Public Account*, 13–18.
- Gujarati, D. y Porter, D. (2010). *Econometría* (5 ed.). México, D.F.: McGraw-Hill.
- Kliestik, T., Misankova, M., Valaskova, K. & Svabova, L. (2018). Bankruptcy Prevention: New Effort to Reflect on Legal and Social Changes. *Science and Engineering Ethics*, 24(2), 791–803. <https://doi.org/10.1007/s11948-017-9912-4>
- Krishnasami, J. (2012). Financial Risk: Impact on Debt-Equity Mix. *SCMS Journal of Indian Management*, 9(1), 43–59. Available from <https://www.scms.edu.in/uploads/journal/January%20-%20March%202012.pdf>
- Kücher, A., Mayr, S., Mitter, C., Duller, C. & Feldbauer-Durstmüller, B. (2020). Firm age dynamics and causes of corporate bankruptcy: age dependent explanations for business failure. *Review of Managerial Science*, 14(3), 633–661. <https://doi.org/10.1007/s11846-018-0303-2>
- Lennox, C. (1999). Identifying failing companies: A reevaluation of the Logit, Probit and DA approaches. *Journal of Economics and Business*, 51(4), 347–364. [https://doi.org/10.1016/s0148-6195\(99\)00009-0](https://doi.org/10.1016/s0148-6195(99)00009-0)
- Lin, T.-H. (2009). A cross model study of corporate financial distress prediction in Taiwan: Multiple discriminant analysis, Logit, Probit and neural networks models. *Neurocomputing*, 72(16–18), 3507–3516. <https://doi.org/10.1016/j.neucom.2009.02.018>
- Martínez, H., Cazallo, A., Meñaca, I. y Uribe, C. (2020). Desempeño financiero de las empresas minoristas de alimentos y bebidas en Barranquilla - Colombia. *Revista de Ciencias Sociales*, 26(1), 144–158. <https://doi.org/10.31876/rcs.v26i1.31316>
- Mittal, S. & Lavina. (2018). The Determinants of Financial Distress in Indian real estate and Construction industry. *Gurukul Business Review*, 14(2), 6–11. Available: <https://gurukulbusinessreview.in/past-issues/>
- Navarrete, G. (2022). Organizaciones inteligentes y su incipiente incursión en la esfera turística. Una aproximación al estado del conocimiento. *Telos Revista de Estudios Interdisciplinarios en Ciencias Sociales*, 24(1), 100–122. <https://doi.org/10.36390/telos241.07>
- Ogachi, D., Ndege, R., Gaturu, P. & Zoltan, Z. (2020). Corporate Bankruptcy Prediction Model, a Special Focus on Listed Companies in Kenya. *Journal of Risk and Financial Management*, 13(3), 1–14. <https://doi.org/10.3390/jrfm13030047>
- Ohlson, J. A. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18(1), 109–131. <https://doi.org/10.2307/2490395>

- Pérez, G., González, C. y Lopera, C. (2013). Modelos de predicción de la fragilidad empresarial: aplicación al caso colombiano para el año 2011. *Perfil de Coyuntura Económica*, (22), 205–228. Disponible en <https://revistas.udea.edu.co/index.php/coyuntura/article/view/20539>
- Rodríguez, C., Maté, M. y López, F. (2020). La proximidad geográfica en el contagio del fracaso empresarial en la pyme: Una aplicación empírica con el modelo Probit espacial. *Estudios de Economía Aplicada*, 34(3), 629–648. <https://doi.org/10.25115/eae.v34i3.3063>
- Romero, F. (2013). Variables financieras determinantes del fracaso empresarial para la pequeña y mediana empresa en Colombia: análisis bajo modelo Logit. *Pensamiento & Gestión*, (34), 235–277. Disponible en <https://rcientificas.uninorte.edu.co/index.php/pensamiento/article/view/5647>
- Romero, F., Melgarejo, Z. & Vera-Colina, M. (2015). Fracaso empresarial de las pequeñas y medianas empresas (pymes) en Colombia. *Suma de Negocios*, 6(13), 29–41. <https://doi.org/10.1016/j.sumneg.2015.08.003>
- Singh, B. P. & Mishra, A. K. (2016). Re-estimation and comparisons of alternative accounting based bankruptcy prediction models for Indian companies. *Financial Innovation*, 2(1), 1–28. <https://doi.org/10.1186/s40854-016-0026-9>
- Solomon, D. C. & Muntean, M. (2012). Assessment of Financial Risk in Firm's Profitability Analysis. *Economy Transdisciplinarity Cognition*, 15(2), 58–67. Available from https://www.ugb.ro/etc/etc2012no2/11_Solomon,_Muntean_final.pdf
- Spekman, R. E. & Davis, E. W. (2004). Risky business: Expanding the discussion on risk and the extended enterprise. *International Journal of Physical Distribution and Logistics Management*, 34(5), 414–433. <https://doi.org/10.1108/09600030410545454>
- Supercias. (2020). Portal de información. *Superintendencia de compañías valores y seguros*. Disponible en https://appscvsmovil.supercias.gob.ec/portalInformacion/sector_societario.zul
- Svabova, L., Michalkova, L., Durica, M. & Nica, E. (2020). Business failure prediction for Slovak small and medium-sized companies. *Sustainability (Switzerland)*, 12(11), 1–14. <https://doi.org/10.3390/su12114572>
- Támara, A. y Villegas, G. (2021). Influencia del entorno financiero, el entorno macroeconómico, la estructura organizacional y la transparencia en la quiebra empresarial. *Contaduría y Administración*, 66(2), 1–23. <https://doi.org/10.22201/fca.24488410e.2021.2618>
- Wu, W. W. (2010). Beyond business failure prediction. *Expert Systems with Applications*, 37(3), 2371–2376. <https://doi.org/10.1016/j.eswa.2009.07.056>
- Zambrano, F., Sánchez, M. y Correa, S. (2021). Análisis de rentabilidad, endeudamiento y liquidez de microempresas en Ecuador. *Retos*, 11(22), 235–249. <https://doi.org/10.17163/ret.n22.2021.03>
- 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>

BIODATA

Iván Felipe Orellana Osorio es contador Público e Ingeniero Comercial de la Universidad del Azuay (Ecuador). Especialista en Docencia Universitaria. Maestría en Administración de Empresas MBA en la Universidad del Azuay. Graduado del Programa de Alta Gerencia del INCAE, y está cursando el Doctorado en Administración en la Universidad Nacional de Rosario (Argentina). Docente de pregrado y posgrado en las cátedras de gerencia, proyectos y finanzas en la Universidad del Azuay y la Universidad de Cuenca (Ecuador). ORCID: <https://orcid.org/0000-0001-6279-2734>

Luis Gabriel Pinos Luzuriaga es economista. Magister en Seguros y Riesgos Financieros. En el campo académico ha cumplido labores de docente en cátedras de Estadística, Econometría, Cálculo actuarial y Administración de riesgos financieros, en cursos de pregrado y postgrado de la Universidad del Azuay (Ecuador) y la Universidad de Cuenca (Ecuador). En los últimos años se ha vinculado a grupos de investigación en la Universidad del Azuay desempeñando labores de soporte en el área cuantitativa. ORCID: <https://orcid.org/0000-0002-3894-8652>

Marco Antonio Reyes Clavijo es ingeniero comercial graduado en la Universidad del Azuay (Ecuador). Obtuvo su Maestría en Administración de Empresas con Mención en Finanzas en la Universidad del Azuay. Actualmente se desempeña como docente en el área de estadística y como técnico financiero e investigador en el Observatorio Empresarial de la Universidad del Azuay. Sus investigaciones se han enfocado en el análisis y gestión del riesgo financiero, aplicado a diferentes sectores económicos del Ecuador. ORCID: <https://orcid.org/0000-0001-5279-4234>

Estefanía del Rocío Cevallos Rodríguez es magíster en Ciencias de manejo de recursos. En la Academia ha cumplido labores de docente de las cátedras de Auditoría ambiental y Evaluación de impactos ambientales en la Facultad de Ciencias de la Administración de la Universidad del Azuay (Ecuador). En los últimos tres años ha estado vinculada al Observatorio empresarial de la misma universidad desempeñando labores de gestión de la información y redacción de artículos científicos y documentos de divulgación de conocimientos. ORCID: <https://orcid.org/0000-0001-8238-2337>

Luis Bernardo Tonon Ordoñez es economista de la Universidad del Azuay (Ecuador). Diplomado Superior en Finanzas, Mercado de Valores y Negocios Fiduciarios, Diplomado Superior en Negociación Internacional. Magister en Administración de Empresas en la Universidad del Azuay. Catedrático en la Universidad del Azuay en las áreas de Economía y Finanzas. Ha participado en diversos grupos de investigación y actualmente es parte del Observatorio Empresarial de la UDA. ORCID: <https://orcid.org/0000-0003-2360-9911>