

Universidad de Lima
Facultad de Ciencias Empresariales y Económicas
Carrera de Economía



COMPARATIVA DE MODELOS DE PREDICCIÓN DE QUIEBRA: UNA APLICACIÓN PARA EL SECTOR MINERO COMPRENDIDO EN EL PERIODO 2009 AL 2015 PARA EL CASO PERUANO

Tesis para optar el Título Profesional de Economista

Miguel Alonzo Cruz Jauregui

Código 20151795

Frances Ariadna Rodrigo Calderon

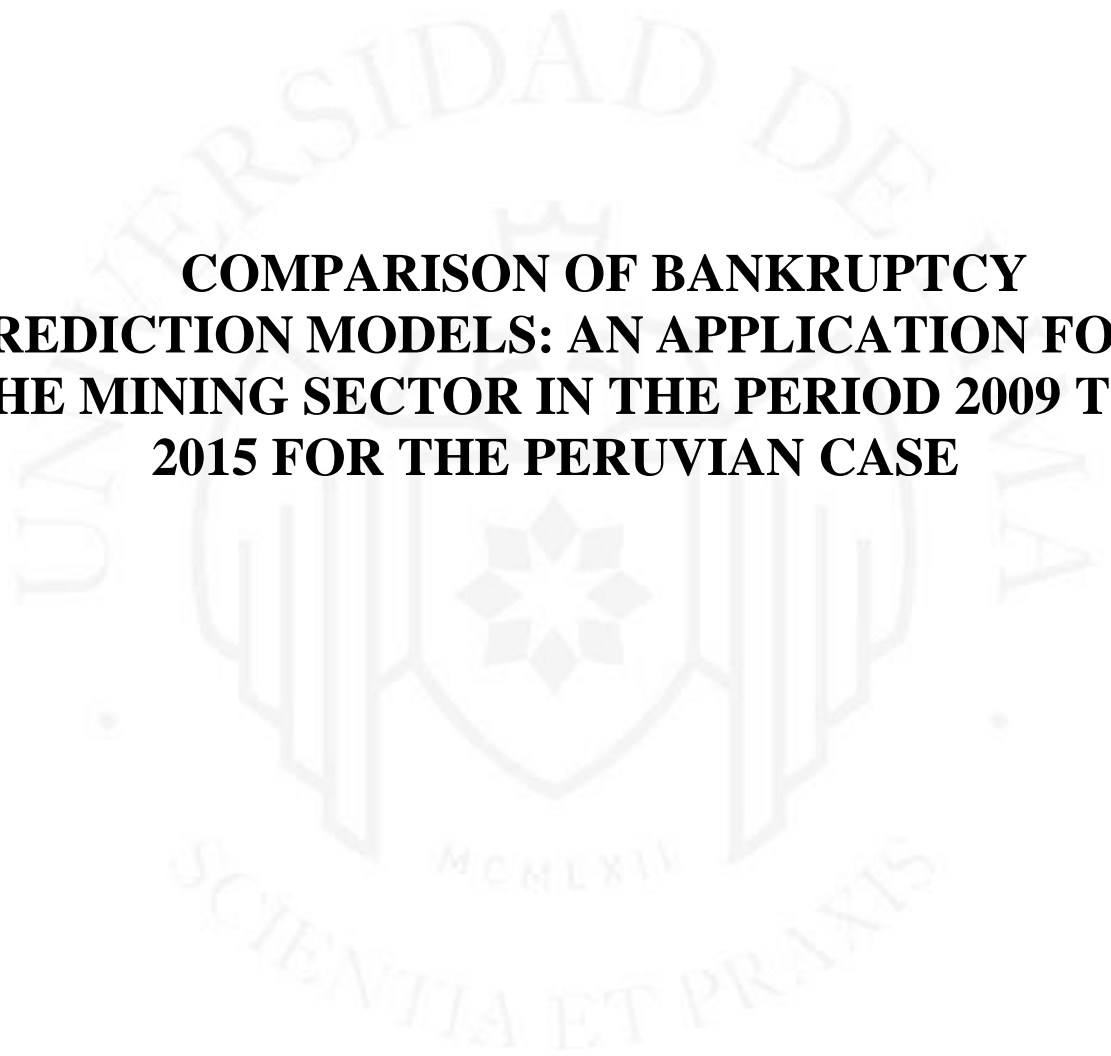
Código 20173817

Asesor

Julio César Del Castillo Vargas

Lima – Perú
Enero del 2025





**COMPARISON OF BANKRUPTCY
PREDICTION MODELS: AN APPLICATION FOR
THE MINING SECTOR IN THE PERIOD 2009 TO
2015 FOR THE PERUVIAN CASE**

TABLA DE CONTENIDO

RESUMEN	vii
ABSTRACT	viii
CAPITULO I: ESTADO DEL ARTE	4
1.1. Principios teóricos	4
1.2. Resumen de literatura.....	10
1.3. Presentación del enfoque propio a utilizar	12
CAPITULO II: METODOLOGÍA DE LA INVESTIGACIÓN	13
2.1. Metodología	13
2.2. Datos y Muestra	14
CAPITULO III: ANÁLISIS DE LOS RESULTADOS	18
CONCLUSIONES	31
RECOMENDACIONES	33
REFERENCIAS	34
BIBLIOGRAFÍA	39

INDICE DE TABLAS

Tabla 1.1 Parámetros de referencia Z-score.....	6
Tabla 2.1 Relación de mineras y metales de producción	14
Tabla 2.2 Relación de mineras clasificadas.....	16
Tabla 3.1 Análisis del Z-score empresas mineras peruanas 2009-2015.....	18
Tabla 3.2 Resultado final sobre probabilidad de las empresas mineras	20
Tabla 3.3 Regresión Logística.....	233
Tabla 3.4 Regresión Logística Final.....	23
Tabla 3.5 Resultados de comando predict.....	24
Tabla 3.6 Resultado final sobre probabilidad de las empresas mineras	25
Tabla 3.7 Matriz de confusión.....	299
Tabla 3.8 Tabla de Falsos Errores	299
Tabla 3.9 Resultado final sobre probabilidad de las empresas mineras Red Neuronal.....	30

INDICE DE FIGURAS

Figura 1.1 Redes Neuronales.....	9
Figura 3.1 Minas clasificadas en zona de peligro	199
Figura 3.2 Matriz de correlación de ratios financieros del modelo Logit	222
Figura 3.3 Minas con clasificación opuesta según Logit	244
Figura 3.4 Red Neuronal Minas	288



RESUMEN

El objetivo de la investigación es identificar la metodología de predicción de quiebra con mayor grado de eficacia para el sector minero entre los años 2009 al 2015. Esta aplicación se realizará para el caso peruano utilizando la información de 16 mineras que se encuentran inscritas en la Bolsa de Valores de Lima. Se realiza la comparación de las 3 metodologías más conocidas para la predicción de quiebras, dichas metodologías son las siguientes: Análisis Discriminante Múltiple, Regresión Logística y Redes Neuronales. Para alcanzar nuestro objetivo, se hará uso de ratios de apalancamiento de cada minera comparándolo con nuestros resultados obtenidos y así obtener cual es la metodología con mayor grado de acierto. Al finalizar de la investigación, se concluye que el modelo de Redes Neuronales cuenta con el mayor grado de eficacia, seguido del modelo Logit y por último el modelo de Análisis discriminante. Lo que nos llevó a realizar esta investigación fue principalmente la importancia que el sector estudiado posee para nuestro país, sumado con la intriga presente en el comportamiento de las mineras peruanas.

Línea de Investigación: 5300 – 3.k5

Palabras Clave: Ratios financieros, Apalancamiento, Quiebra, Modelo de Análisis discriminante, Modelo Logit, Modelo de Redes neuronales.

ABSTRACT

The research aims to find the most effective bankruptcy prediction methodology for the mining sector between 2009 and 2015. This application will be carried out in the Peruvian case using a sample of 16 listed mining companies. the Lima Stock Exchange. A comparison of the 3 best-known methodologies for bankruptcy prediction is made, these methodologies are the following: Multiple discriminant analysis, logistic regression, and neural networks. In order to achieve our objective, the leverage ratios of each mining company will be used, comparing it with our results obtained and thus obtaining the methodology with the highest degree of success. At the end of our investigation, it is obtained that the Neural Networks model has the highest degree of efficiency, followed by the Logit model and finally the Discriminant Analysis model. What led us to carry out this investigation was mainly the importance that the studied sector has for our country, added to the intrigue present in the behavior of Peruvian mining companies.

Line of research: 5300 – 3.k5

Key words: Financial Ratios, Leverage, Bankruptcy, Discriminant Analysis Model, Logit Model, Neural Networks Model.

INTRODUCCIÓN

La economía peruana se caracteriza por tener como pilar principal de crecimiento la exportación metálica, dentro de los cuales se encuentran principalmente el cobre, oro, zinc, plata y plomo. (Ministerio de Energía y Minas, 2015). Además, la actividad minera ayuda significativamente a la generación de empleo, recaudación fiscal y al desarrollo sostenible de las comunidades involucradas, fortaleciendo de esa manera la economía nacional.

A mediados del 2008, empieza la crisis financiera más grande de la década en el mercado hipotecario estadounidense. Esto repercutió no solo en la economía americana, sino también fue de carácter global. El efecto negativo en el mercado internacional se reflejó en la disminución del comercio exterior mundial; como consecuencia, la demanda y precios de los minerales disminuyeron, perjudicando directamente a la economía peruana, reduciendo los niveles de exportación por la baja demanda internacional. Para el primer trimestre del 2009, se reportó una reducción de precios promedio de cobre y zinc por 36.1% (BCRP, 2009).

Por otro lado, China logró mantenerse al margen de los efectos de la crisis y no fue afectada por esta. Durante este periodo, su economía tuvo un crecimiento significativo impulsado por un aumento en la inversión en infraestructura; como consecuencia, el nivel de demanda y precios de minerales aumentó, por lo que China se convirtió en el principal cliente en el mercado peruano, llegando a registrar 4,082 millones de dólares (BCRP, 2009). A mediados del 2010 e inicios del 2011, las economías internacionales fueron recuperándose de la crisis, por lo que el nivel de exportación aumentó, por ende, el nivel de precios no disminuyó significativamente. Esta recuperación determinó que los niveles de demanda aumenten causando el auge de la exportación de metales en 34% (MINCETUR, 2011). En el 2012, se produce una desaceleración económica en China, el principal importador del Perú, lo que afectó a las exportaciones peruanas. Esto generó una reducción tanto en los precios como en la demanda de los minerales, tendencia que se mantuvo hasta el 2015. El mercado de los *commodities* presenta un impacto significativo

sobre las variaciones diarias con respecto al nivel de precios y demanda, generando mucha incertidumbre en las empresas mineras.

Glave (2007) argumenta que las fluctuaciones de los precios tienen un efecto directo sobre el desempeño de las empresas mineras, por ende, muchas veces estas no cuentan con las estrategias que puedan controlar los efectos de incertidumbre. En un contexto en el que las empresas mineras no cuenten con un modelo de predicción eficaz, esto desencadenaría en posibles problemas financieros, puesto que no se podrían emitir soluciones sobre la posible quiebra, sobre todo si se tratan de empresas en economías emergentes como es el caso peruano. Como solución a esta problemática proponemos un sistema de alerta que pueda detectar los problemas de una empresa de manera temprana, para poder reducir la exposición, hecho que mitiga los riesgos de contagio financiero. En consecuencia, el presente estudio examina la predicción de los modelos de quiebra en el sector minero dentro del caso peruano durante el periodo del 2009 al 2015, de tal manera que se obtenga el modelo con mayor grado de acierto y eficacia.

El objetivo general de nuestra investigación es determinar qué modelo de predicción es el más adecuado para predecir quiebras en el sector minero para el caso peruano durante el periodo del 2009 al 2015. En base al objetivo general, se determinará el grado de acierto de los modelos de Redes Neuronales, Regresión Logística y Análisis Discriminante Múltiple. Se seleccionaron dichos modelos porque se buscó comparar metodologías propuestas en diferentes periodos de tiempo y por su eficacia, validada en estudios previos. En primer lugar, Khawaja (2023) revela que la quiebra financiera de los bancos en Pakistán se puede predecir con éxito por la metodología del Análisis Discriminante Múltiple. Por otro lado, Huo, Chan y Miller (2024) determinan que el modelo Logit funciona mejor que el Análisis Discriminante Múltiple en cuanto a la predicción de probabilidad de quiebra para aquellas compañías que cotizan en Bolsa en Estados Unidos, pero que ambos miden con eficacia sus capacidades predictivas.

Existen diversas investigaciones que afirman la eficacia del modelo de Red Neuronal en términos de poder predecir una quiebra; por lo que, dentro de la investigación la hipótesis planteada es que el modelo de Redes Neuronales presenta un nivel de acierto

de quiebra superior que el modelo de Análisis Discriminante Múltiple y modelo Logit en el sector minero entre el periodo 2009 al 2015. Autores como Chocce y Palma (2002) realizan el análisis que el modelo de redes neuronales presenta un desempeño acertado sobre la clasificación de la quiebra empresarial como también en Tsai y Wu (2008) se concluye que la precisión de las redes neuronales supera a otros modelos como el Análisis Discriminante Múltiple y Regresión Logística. Además, Leshno y Spector (1996) para la estimación de aquellas compañías pertenecientes a la Bolsa de Valores de New York se indica que la capacidad predictiva de redes neuronales es más aceptada que el análisis discriminante clásico.

Para organizar la data se han dividido a las mineras como “frágiles” y “no frágiles” utilizando como referencia para la clasificación el ratio de apalancamiento. Fattouh, Pisicoli y Scaramozzino (2024) indican que el apalancamiento excesivo es un predictor significativo del cierre para empresas italianas. Adicionalmente, se afirma que las empresas que no cuentan con riesgo de solvencia (ratio de apalancamiento moderado) mantienen un nivel de liquidez estable y no sufren fragilidad financiera (Horobet et al., 2021).

El documento se organizará de la siguiente manera. En la primera sección se desarrollará el capítulo del estado del arte. Este se dividirá en dos secciones: marco teórico, donde se especificarán las teorías que se emplearán para el desarrollo de los modelos que predicen la quiebra, y revisión de literatura, donde se sustenta la evidencia empírica del tema de investigación. En la segunda sección, se determinará el capítulo de datos y variables. El propósito de esta investigación es demostrar qué modelo de predicción de bancarrota es el más preciso, utilizando el Análisis Discriminante Múltiple, Regresión Logística y Redes Neuronales. Por este motivo, se utilizan 16 empresas listadas en la Bolsa de Valores de Lima. La recolección de datos se obtuvo extrayendo la información financiera de la plataforma Economatica. En la tercera sección, el capítulo de método de contrastación explicará el proceso matemático de desarrollo de cada uno de los modelos de quiebra propuestos. Para el trabajo de investigación, utilizaremos tres métodos econométricos para comprobar y comparar los resultados de la predicción de los resultados de bancarrota para cada empresa minera de la muestra.

CAPITULO I: ESTADO DEL ARTE

1.1. Principios teóricos

La insolvencia de las empresas se origina por el incumplimiento de las obligaciones, el cual se induce a partir de la reducción de los ingresos, el incremento de los costos y el aumento del apalancamiento. La predicción de bancarrota es un tema importante de tratar, debido a las decisiones de financiamientos e inversión, se debe de tener en cuenta todas las posibles condiciones que pueden determinar un fracaso y estudiar el comportamiento (Podobnik, 2010). Es así como se crearon los modelos que ayudan a predecir la quiebra, donde podemos encontrar distintos planteamientos, proporcionando una alternativa de alerta sobre las posibles situaciones de fragilidad empresarial. Los modelos de predicción pueden determinar por diferentes condiciones como comportamiento de mercado, financiamiento, deficiente toma de decisiones, ciclos económicos, entre otros.

En primer lugar, el Análisis Discriminante Múltiple (ADM) es una técnica que se encarga de clasificar un número de observaciones dentro de la muestra que no se superponen en base a una función de puntuaciones de una o más variables predictoras. Dentro de los objetivos de Análisis Discriminante Múltiple está determinar las relaciones de las variables continuas que puedan determinar un resultado con precisión para evaluar el sector en análisis. Altman (1968) desarrolló el modelo Z-score utilizando el Análisis Discriminante Múltiple para poder predecir en el caso de las empresas corporativas, donde identifica los posibles ratios financieros que puedan ser considerados como los más relevantes para una predicción de quiebra. Específicamente, se analizan empresas de manufactura en los Estados Unidos, clasificando a las compañías en dos grupos: en situación quiebra y no quiebra. Antes de proponer la ecuación, se encargó de seleccionar las razones financieras que influyen más sobre el posible escenario de quiebra financieras. Altman (1963) calcula los coeficientes de la función discriminante utilizando un grupo de empresas que fueron declaradas en quiebra y las comparó con empresas de igual tamaño en el mismo sector.

Seguidamente, Altman (1968) propone la siguiente función discriminante para poder realizar el análisis:

$$Z_{score} = 0.012X1 + 0.014X2 + 0.033X3 + 0.006X4 + 0.999X5$$

Donde:

X1: Capital de trabajo/Activo Total

X2: Utilidad retenida/Activo Total

X3: EBITDA/Activo Total

X4: Valor de mercado accionario/Pasivos Totales

X5: Ventas Netas/Activos Totales.

Posteriormente, Altman (1968) empezó a recibir muchas críticas, puesto que el modelo planteado inicialmente sólo podía estudiar a las empresas manufactureras que estén cotizando en bolsa. Esto tuvo como consecuencia que cambie la variable de Valor de mercado accionario/Pasivos totales por valor contable/pasivos totales para que se puedan incluir para las empresas que no cotizan en bolsa. Asimismo, para que esta función discriminante pueda utilizarse en cualquier tipo de sector se tuvo que eliminar la variable Ventas netas/activos totales. Este cambio que planteó Altman (1983) ayudó a en predecir quiebra dentro de las economías en vías de desarrollo (Bermeo, 2021).

La ecuación final modificada por Altman (1983) se representa de la siguiente forma:

$$Z_{score} = 6.56X1 + 3.26X2 + 6.72X3 + 1.05X4$$

Donde:

X1: Capital de trabajo / Activo Total

X2: Utilidad retenidas/Activo Total

X3: EBITDA/Activos Totales

X4: Valor contable /Pasivos Totales

Para clasificar los resultados obtenidos, se tomó en consideración los siguientes parámetros:

Tabla 1.1*Parámetros de referencia Z-score*

Nombre del Resultado	Interpretación
Zona Segura	En el caso que el valor sea superior a 2.99, existe una baja probabilidad de bancarrota.
Zona de Peligro	En el caso que el valor sea inferior a 1.8, existe una alta probabilidad de bancarrota.
Zona Gris	Los valores que oscilan entre 1.8 y 2.99 determinarán una posibilidad de bancarrota en dos años.

Nota. Elaboración propia. Adaptado de “Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. The Journal of Finance”, por Altman, 1963, (<https://doi.org/10.2307/2978933>).

El modelo de Análisis Discriminante Múltiple (ADM) propuesto por Altman (1968) presenta como ventaja una cantidad específica de variables a utilizar, las que se encuentran en la ecuación planteada, produciendo así un modelo que no se limite en un análisis univariado. Altman, Danovi y Falini (2013) enfatizan que el modelo reportó un 95% de efectividad y este propone un rango de zonas de respuesta sobre una puntuación que ayuda en la clasificación entre las interpretaciones propuestas. Altman (1983) se encarga de adaptar el modelo para que pueda ser utilizado en distintas industrias, asegurando un nivel de predicción alto. Por otro lado, el Análisis Discriminante Múltiple (ADM) ha sido una técnica popular en estudios de quiebra, pero presenta varios problemas, entre estos, el modelo presenta una zona gris extensa, y esto puede dificultar el poder de predicción en un escenario de quiebra financiera (Joy et al., 1975). Asimismo, el modelo carece de distintas pruebas estadísticas, por lo que las variables independientes pueden llegar a estar altamente correlacionadas e incurre en inestabilidad de los coeficientes en la ecuación, por consiguiente, generando errores estándares, lo que no es un modelo de alta probabilidad de predicción (Johnson, 1970).

El segundo modelo de predicción de quiebra es Regresión Logística, el cual tiene como objetivo poder determinar la probabilidad de impacto de los escenarios propuestos sobre diferentes variables. El modelo de probabilidad se presenta la siguiente manera:

$$P_Q = P(Y_i = 1) = \frac{e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n}}{1 + e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}}$$

Donde:

β_n : Coeficientes de la variable independiente

X_n : Variables independientes de la muestra.

Dentro del modelo Logit, la variable independiente X_n hace referencia al vector de unidades predictoras de las observaciones, donde este se encuentra multiplicado con el coeficiente β_n , teniendo como finalidad evaluar el impacto de probabilidad estimada de estar dentro de un resultado dicotómico, el que indica la probabilidad de tomar los valores de 0 o 1, en vez de dar como respuesta un resultado de estimación continua. (Stoltzfus, 2011).

Ohlson (1980) propone que para evaluar los coeficientes β_n y determinar los resultados de la muestra en estudio se encuentren dentro del escenario de probabilidad de quiebra y no quiebra formulando lo siguiente:

$$L(\beta_n) = \sum \log P_Q + \sum \log (1 - P_Q)$$

Seguidamente, se emplea la función de máxima verosimilitud para los datos observados:

$$L(\beta_n) = \sum_{i=1}^N ((Y_i \ln(P_Q) + (1 - Y_i) \ln(1 - P_Q))$$

Una de las ventajas al utilizar el modelo Logit es que no asume la linealidad entre variables independientes, evitando problemas estadísticos de distribución de predictores, en la matriz de varianza-covarianza y normalidad, por lo que permite estimar la probabilidad de quiebra sin complicaciones adicionales. Cabe resaltar que este modelo es eficaz para analizar, cómo distintas variables pueden influir en la capacidad probabilística de que una compañía atraviese por dificultades financieras (Hosmer et al., 1980). En cuanto a las desventajas del modelo Logit, estas se visualizan en los valores atípicos, ya que pueden generar inconsistencia cuando se emplea la función de máxima verosimilitud en la estimación de los coeficientes (Bianco et al., 2009). Asimismo, Wooldridge (2009) establece que el porcentaje de predicción resulta como medida de la bondad de ajuste; sin

embargo, cuando existe una muestra grande, la respuesta de probabilidad final puede ser engañosa, por lo que puede generar inconsistencias al comparar la muestra real contra el resultado del modelo.

El tercer modelo en estudio es Redes Neuronales, el cual se caracteriza por replicar el sistema neuronal del ser humano compuesto por elementos de interconexión denominados neuronas o nodos (Lin, 2009). El objetivo del modelo es proponer un sistema de interconexión de las unidades en análisis. Este se encarga de dividir las redes en tres neuronas, las cuales son: capa de entrada, oculta y salida. Para la primera capa que señala la entrada tomará el valor aquellas variables dependientes; la capa oculta se encarga de establecer los grados de libertad que una neurona presenta sobre la entrada; y la que determina la respuesta es la capa de salida. Las redes neuronales se caracterizan por estar conformada por nodos. Estos nodos representan las variables dependientes que ingresarán dentro de la capa de entrada que representan un conjunto de conexiones directas que determinan el punto de partida en el análisis. Seguidamente, se transmitirá la información hacia la capa oculta que se encarga de procesar los datos logrando reportar una respuesta hacia la capa de salida, la cual mediante un nodo determinará la respuesta, logrando establecer si existe fragilidad empresarial o no. (Fernández-Gómez et. al, 2016)

Para poder demostrar el modelo de redes neuronales se tomará en cuenta el modelo de Perceptrón Multicapa (MLP), el cual se caracteriza por realizar la propagación de redes neuronales hacia adelante (Wirgard, 2022). Rosenblatt (1958) presentó que el perceptrón de una capa oculta solo podía resolver funciones lineales, asimismo, demostró que existían ciertas limitaciones con las funciones no lineales, puesto que no se podían resolver. Posteriormente, Rumelhart, Hinton y Williams (1986) propusieron un modelo de perceptrón multicapa moderno con retropropagación, en el que supieron cómo resolver las limitaciones del modelo anterior, logrando establecer que el modelo se puede emplear para funciones tanto lineales como no lineales, permitiendo así poder reconocer los patrones con eficiencia. La fórmula propuesta es la siguiente:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

Donde:

y : Suma de nodos de entrada

x_i : Neuronas o nodos de entrada

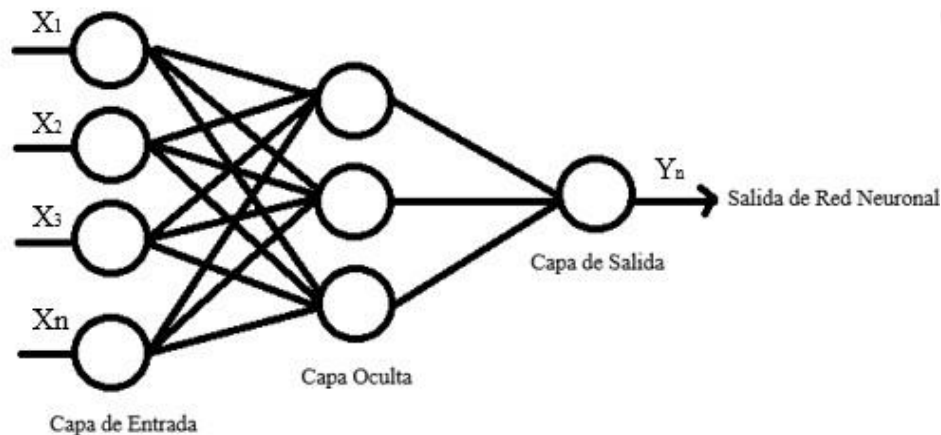
w_i : Pesos que deben de estar conectados con la unidad de análisis de la muestra

b : Sesgos

Los nodos o neuronas de una red neuronal se multiplican con pesos, los cuales miden la conexión y determinan qué partes se consideran útiles para la realizar la conexión con la capa de entrada. Seguidamente, se activa la función determinando una señal de salida, el resultado obtenido se compara contra el valor objetivo de predicción. Para poder minimizar la cantidad de errores en la función, este pasará por el proceso denominado retropropagación (Rumelhart et al., 1986).

Figura 1.1

Redes Neuronales



Nota. Elaboración propia. Adaptado de “Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the italian experience)”, por Edward I. Altman, 1994, 18, p. 513 ([https://doi.org/10.1016/0378-4266\(94\)90007-8](https://doi.org/10.1016/0378-4266(94)90007-8))

Las redes neuronales se consideran como un modelo con enfoque sólido que no requiere que las variables se distribuyan en conjunto como otros modelos, por lo que es una técnica de predicción robusta (Wilson et al., 1994). Además, las redes neuronales tienen la capacidad de tener resultados más precisos a comparación de otros modelos de predicción. Por otro lado, para poder entrenar el modelo de Redes neuronales, se requiere desarrollar distintas pruebas para poder llegar a una estructura; además, si es que se generan varias capas, se puede llegar a tomar ciertas limitaciones, llegando a tener como respuesta

pesos sensibles que determine un comportamiento ilógico de respuesta (Altman et al., 1994).

1.2. Resumen de literatura

Diversos autores se han dedicado en la investigación de los modelos de predicción y obtuvieron los siguientes resultados.

Leshno y Spector (1990) estudian el caso de bancarrota sobre las compañías de la Bolsa de valores de New York (NYSE). Evaluaron los casos a partir del modelo de Análisis Discriminante Múltiple y Modelo de Red Neuronal. Los resultados indicaron que las capacidades de predicción de Redes Neuronales son más aceptadas que el Análisis Discriminante clásico. Etheridge y Sriman (1997) compararon tres modelos de predicción de quiebra: Análisis Discriminante Múltiple, Modelo Logit y Redes Neuronales para el caso de bancos de Estados Unidos entre 1986 y 1988. Dentro de la investigación, utilizaron distintos ratios financieros que ayudaron a la predicción y obtuvieron como respuesta que el modelo de redes neuronales logra predecir la cantidad exacta de empresas que sufrieron bancarrota. Chocce et al. (2002) estudiaron el caso de las empresas mineras chilenas. Dentro de la comparativa seleccionaron los siguientes métodos de predicción: Análisis Discriminante, Regresión Logística y Redes Neuronales. Dentro del planteamiento opta por seleccionar indicadores financieros, variables macroeconómicas y variables de control. Como resultado, la estimación determinó que el modelo de Redes Neuronales obtiene un resultado más preciso sobre la predicción de bancarrota. Chung et al. (2008) analizaron la predicción de quiebra de empresas en Nueva Zelanda entre los años 1989 y 1995. Los modelos de predicción de quiebra que se compararon fueron el Análisis Discriminante Múltiple y el modelo de Redes Neuronales. El modelo que logró demostrar una mejor relación no lineal entre las razones financieras empleadas en el estudio y precisión en predicción de empresas en quiebra y no quiebra fue el modelo de Redes Neuronales. Odom y Ramesh-Sharda (2013) emplearon las mismas variables que Altman (1968) para evaluar los modelos de bancarrota del Análisis Discriminante Múltiple y la Red Neuronal. Esta investigación compara los métodos que se han convertido en "regla" de predicción de

bancarrota, y la Red Neuronal mostró un mejor desempeño. Lee y Choy (2013) realizaron un estudio de predicción de quiebras multisectorial de las industrias de construcción, fabricación y comercio en Corea. Se realizó una comparativa entre el modelo Logit multidimensional y el modelo de Redes neuronales, utilizando como variables de análisis el crecimiento, rentabilidad, productividad, liquidez y calidad de activos. El estudio demostró que el modelo de Redes neuronales logra capturar con mayor exactitud el patrón no lineal y acierto sobre la cantidad de empresas declaradas en bancarrota. Inam et al. (2018) compararon tres modelos de predicción de quiebra: Análisis Discriminante Múltiple, modelo Logit y modelo de Redes Neuronales para las empresas de Pakistán entre 1995 y 2017. El modelo de Redes Neuronales superó la capacidad de predicción de quiebra, logrando acertar la cantidad de empresas que se encontraban en quiebra y no quiebra financiera. Asimismo, Hyeongjun y Hoon (2022) utilizaron la metodología de *machine learning*, el modelo de redes neuronales y regresión logística para estimar el mejor modelo predictivo. Tomaron en cuenta los indicadores financieros de la muestra de empresas quebradas y sin quebrar. La metodología de Redes Neuronales tiene un mejor pronóstico de rendimientos relativos al modelo de Regresión Logística.

En la última década, no existen muchos trabajos que respalden lo propuesto por Altman (1963) y la regresión logística. Dentro de los estudios encontrados, Ohlson (1980) estudia el caso del sector empresarial donde compara el Análisis Discriminante con el modelo Logit. Dentro del análisis el modelo discriminante resultó el más preciso, pero enfatiza que la capacidad de predicción de los modelos es en base de los resultados financieros del periodo. Fang-Mei y Yi-Chung Hu (2010) tuvieron en cuenta cuatro modelos de predicción de una muestra de 77 empresas en Inglaterra, entre estos estaban: Regresión Logística, Logit de intervalo cuadrático, Redes Neuronales y Redes Difusas. Concluyeron que el método Logit es una herramienta alternativa prometedora cuando no se cumplen los supuestos estadísticos tradicionales. Mihalovič (2016) comparó el modelo de análisis discriminante múltiple y el modelo Logit para desarrollar la predicción de quiebra de empresas de la República Eslovaca entre el 2008 y 2014. Dentro del estudio se seleccionaron 236 empresas dividiéndolas entre empresas fallidas y no fallidas. El modelo Logit fue el que obtuvo un mayor grado de acierto sobre la muestra, enfatizando que las variables predictoras con mayor grado de eficacia fueron el ingreso neto sobre activos

totales, pasivo corriente sobre activos totales y el coeficiente corriente. Asimismo, Jaffari, y Ghafoor (2017) realizaron un estudio sobre la predicción de quiebra corporativa de las empresas de Pakistan comparando el modelo de Análisis Discriminante Múltiple y el modelo Logit. Examinaron 70 empresas entre los años 1996 y 2012. Dentro de los resultados obtenidos, el modelo Logit logró un 80% de precisión, mientras que el modelo de Análisis Discriminante Múltiple obtuvo un 78.6% de capacidad predictiva. Hu, Chan y Miller (2024) realizaron el análisis comparativo entre el modelo de análisis discriminante y regresión logística entre los años 2000 y 2019 en Estados Unidos. Tomaron como muestra 36 empresas frágiles y 36 empresas no frágiles. Como resultado de los modelos, llegaron a la conclusión que el modelo Logit mostró mayor eficacia en predicción, pero resalta que los modelos determinan con datos fuera de la muestra una predicción similar.

1.3. Presentación del enfoque propio a utilizar

Como se mencionó anteriormente, dentro del trabajo de investigación, se emplearán tres metodologías como modelos de predicción. Además, se comparan dichos modelos y se proporcionará como respuesta un posible escenario de fragilidad financiera en el sector minero para el caso peruano. Asimismo, el planteamiento de estudio se diferencia en la importancia del sector en análisis para el país y en la complejidad, puesto que es un sector difícil de predecir por distintas circunstancias externas como el escenario político, social o económico. Como resultado final, se tendrá como respuesta qué modelo es el más específico para el sector en análisis; adicionalmente, se aportará un modelo que pueda dar mensajes de alerta sobre la predicción de una posible bancarrota.

CAPITULO II: METODOLOGÍA DE LA INVESTIGACIÓN

2.1. Metodología

El primer modelo de estimación es el Análisis Discriminante Múltiple (ADM) para el caso de aplicación se utilizará el modelo de Z-score de Altman (1983), donde se tomará en cuenta el segundo modelo que planteó que pueda ser aplicado para todos los sectores y economías emergentes. Altman (1983) representa la ecuación de la siguiente manera:

$$Z = 6.56 X1 + 3.26 X2 + 6.72 X3 + 1.05 X4$$

Donde:

X1: Capital de Trabajo / Activo Total

X2: Utilidades Retenidas / Activo Total

X3: Utilidades antes de intereses e impuestos / Activo Total

X4: Valor contable / Activo Total

Con respecto al segundo modelo, la Regresión Logística partirá sobre la variable dependiente que es el logaritmo de las probabilidades, el cual hace referencia a la relación entre los escenarios de ocurrencia de quiebra, los cuales son los siguientes: 0 cuando la empresa no es frágil y 1 cuando la empresa es frágil. Las variables independientes que se tomarán en consideración son los siguientes ratios: Pasivo LP/Patrimonio (PLPPATR), Activo corriente/Pasivo corriente (ACRPCR), Utilidad antes de Imp./Activo (UIACT), Utilidad operativa/Activo (UTNAT), Deuda/Activo (DETAT) y Capital/Activo (CATAT). La estimación se medirá a través de la ecuación del modelo Logit:

$$P(Y_i = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 * PLPPATR + \beta_2 * ACRPCR + \beta_3 * UIACT + \beta_4 * UTNAT + \beta_5 * DETAT + \beta_6 * CATAT)}}$$

Donde:

$$\text{Logit } P(Y=1|X_i) = \beta(0) + \beta(1)*PLPPATR + \beta(2)*ACRPCR + \beta(3)*UIACT + \beta(4)*UTNAT + \beta(5)*DETAT + \beta(6)*CATAT$$

Seguidamente, antes de correr el modelo econométrico, se realizará la prueba de correlación para estimar si las variables presentan problemas de multicolinealidad. Por

último, se correrá la función predictiva para calcular realizar el cálculo de probabilidad.

Para la estimación del Modelo de Perceptrón Multicapa (MLP) de Redes neuronales, se tendrá en cuenta los nodos o neuronas de entrada x_i las siguientes razones financieras: Pasivo LP/Patrimonio (PLPPATR), Activo corriente/Pasivo corriente (ACRPCR), Utilidad antes de Imp./Activo (UIACT), Utilidad operativa/Activo (UTNAT), Deuda/Activo (DETAT) y Capital/Activo (CATAT). Las capas ocultas se dividirán en los dos escenarios de probabilidad donde la empresa no frágil tomará el valor de 0 y la empresa frágil 1. Finalmente, se obtiene una matriz de confusión en la que se observan los posibles errores del modelo.

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

2.2. Datos y Muestra

Para desarrollar las metodologías que se aplicarán en la investigación, se seleccionaron mineras peruanas inscritas en la Bolsa de Valores de Lima, extrayendo la información financiera de Economática. Los datos tienen un periodo de análisis desde el 2009 al 2015 seleccionando una frecuencia trimestral para abarcar una mayor cantidad de observaciones en el análisis.

Tabla 2.1

Relación de mineras y metales de producción

Nombre de Minera	Metales
Castrovirreyna Compañía Minera S.A.	Se encarga de explotar y comercializar plata, oro, plomo y zinc
Shougang Hierro Perú S.A.A.	Se encarga de explotar y comercializar el mineral hierro
Compañía Minera San Ignacio de Morococha S.A.A.	Se encarga de explotar y comercializar plomo y zinc
Nexa Resources Atacocha S.A.A.	Se encarga de explotar y comercializar cobre, plomo, zinc y oro y plata.
Sociedad Minera Corona S.A.	Se encarga de explotar y comercializar plata, cobre, plomo y zinc
Compañía Minera Poderosa S.A.	Se encarga de explotar y comercializar el mineral oro
Volcan Compañía Minera S.A.A.	Se encarga de explotar y comercializar plata, cobre, plomo y zinc

(continúa)

(continuación)

Nombre de Minera	Metales
Compañía Minera Santa Luisa S.A.	Se encarga de explotar y comercializar el mineral cobre, plomo y zinc
Sociedad Minera El Brocal S.A.A.	Se encarga de explotar y comercializar plata, cobre, plomo y zinc
Sociedad Minera Cerro Verde S.A.A.	Se encarga de explotar y comercializar cobre y molibdeno
Southern Peru Copper Corporation - Sucursal Del Perú	Se encarga de explotar y comercializar el mineral cobre
Minera Andina de Exploraciones S.A.A.	Se encarga de explotar y comercializar cobre y molibdeno
Minsur S.A.	Se encarga de explotar y comercializar el mineral de estaño y oro
Compañía de Minas Buenaventura S.A.A.	Se encarga de explotar y comercializar plata y oro.
Perubar S.A.	Se encarga de explotar y comercializar cobre y zinc
Fosfatos del Pacífico S.A.	Se encarga de explotar y comercializar minerales de fosfatos

Nota. Información de producción de metales por minera recogida del mapa de principales unidades mineras en Producción, por Ministerio de Economía y Minas, 2024 (<https://www.gob.pe/institucion/minem/informes-publicaciones/5724261-mapa-de-principales-unidades-mineras-en-produccion-2024>)

Particularmente, en el sector minero, son pocos los casos en los que se declaren necesariamente a una empresa en quiebra o bancarrota, en muchas ocasiones las entidades mineras han optado por un plan de contingencia antes de llegar a dar por declarada la quiebra. Beaver (1996) enfatiza que las empresas utilizan los ratios financieros para detectar la fragilidad financiera de una empresa, esto hace que las empresas apliquen una gestión adecuada para evitar la posible quiebra.

Debido a este comportamiento del sector, hemos calculado el ratio de apalancamiento de cada una de las empresas para evaluar el posible escenario de quiebra. Coaquira y Chavez (2021) presentan evidencia empírica mostrando que el apalancamiento de una entidad determina significativamente la gestión financiera. Para tener un panorama sobre el desempeño de las mineras seleccionadas, se dividió a las 16 empresas mineras en empresas “frágiles” y “no frágiles”.

Una vez calculado dicho ratio para las empresas mineras en evaluación, se clasificaron de la siguiente manera:

Tabla 2.2*Relación de mineras clasificadas*

Nombre de Mineras	Clasificación
Castrovirreyna Compañía Minera S.A.	Frágil
Shougang Hierro Perú S.A.A.	Frágil
Compañía Minera San Ignacio de Morococha S.A.A.	Frágil
Nexa Resources Atacocha S.A.A.	Frágil
Sociedad Minera Corona S.A.	Frágil
Compañía Minera Poderosa S.A.	Frágil
Volcan Compañía Minera S.A.A.	No Frágil
Compañía Minera Santa Luisa S.A.	No Frágil
Sociedad Minera El Brocal S.A.A.	No Frágil
Sociedad Minera Cerro Verde S.A.A.	No Frágil
Southern Peru Copper Corporation - Sucursal Del Perú	No Frágil
Minera Andina de Exploraciones S.A.A.	No Frágil
Minsur S.A.	No Frágil
Compañía de Minas Buenaventura S.A.A.	No Frágil
Perubar S.A.	No Frágil
Fosfatos del Pacifico S.A.	No Frágil

Realizando el cálculo del ratio de apalancamiento, se obtuvo que se cuenta con 6 mineras con clasificación “Frágil”. Estas 6 mineras son las siguientes: Castrovirreyna Compañía Minera, Shougang Hierro Perú, Compañía Minera San Ignacio de Morococha, Nexa Resources Atacocha, Sociedad Minera Corona y Compañía Minera Poderosa.

Para el caso del Análisis Discriminante del modelo de Altman (1960), se han empleado para la muestra las mismas variables que se utilizó en su modelo de estimación. Las variables que decide tomar en consideración son la de su segundo Z-score propuesto, puesto que llegó a la conclusión que al retirar la quinta variable ayudaría a poner en práctica el modelo para distintos sectores y no solo enfocarse en su primer estudio del sector manufactura. Las razones financieras utilizadas son las siguientes: Capital de Trabajo / Activo Total, Utilidad retenida / Activo total, Utilidades antes de Int. E Imp. / Activo Total y Valor del Mercado / Activo Total.

Posteriormente, en el modelo Logit y de Red Neuronal, se están toman aquellas variables que se repitieron más en los distintos análisis desarrollados en la revisión de literatura por distintos autores. Muchos de estos fundamentaban que estas variables podrían ayudar a determinar la señal de alerta sobre una posible bancarrota. Dentro de los indicadores financieros se encuentra el Pasivo LP/Patrimonio, Activo corriente/Pasivo corriente, Utilidad antes de Imp./Activo, Utilidad operativa/Activo, Deuda/Activo y Capital/Activo.



CAPITULO III: ANÁLISIS DE LOS RESULTADOS

El modelo de Altman (1983) se calculará con Análisis Discriminante Múltiple en las 16 compañías mineras, se obtuvieron los siguientes Z score:

Tabla 3.1

Análisis del Z-score empresas mineras peruanas 2009-2015

Minera	Z Score	Zona de clasificación
Sociedad Minera Corona S.A.	5.17	Zona Segura
Southern Peru Copper Corporation - Sucursal Del Perú	4.36	Zona Segura
Castrovirreyna Compañía Minera S.A.	0.32	Zona Peligro
Shougang Hierro Perú S.A.A.	2.12	Zona Gris
Perubar S.A.	1.85	Zona Gris
Compañía de Minas Buenaventura S.A.A.	1.66	Zona Peligro
Nexa Resources Atacocha S.A.A.	4.76	Zona Segura
Compañía Minera Santa Luisa S.A.	3.16	Zona Segura
Sociedad Minera El Brocal S.A.A.	3.14	Zona Segura
Fosfatos del Pacifico S.A.	1.05	Zona Peligro
Minera Andina de Exploraciones S.A.A.	9.09	Zona Segura
Minsur S.A.	4.23	Zona Segura
Compañía Minera Poderosa S.A.	1.91	Zona Gris
Compañía Minera San Ignacio de Morococha S.A.A.	0.29	Zona Peligro
Sociedad Minera Cerro Verde S.A.A.	5.15	Zona Segura
Volcan Compañía Minera S.A.A.	3.66	Zona Segura

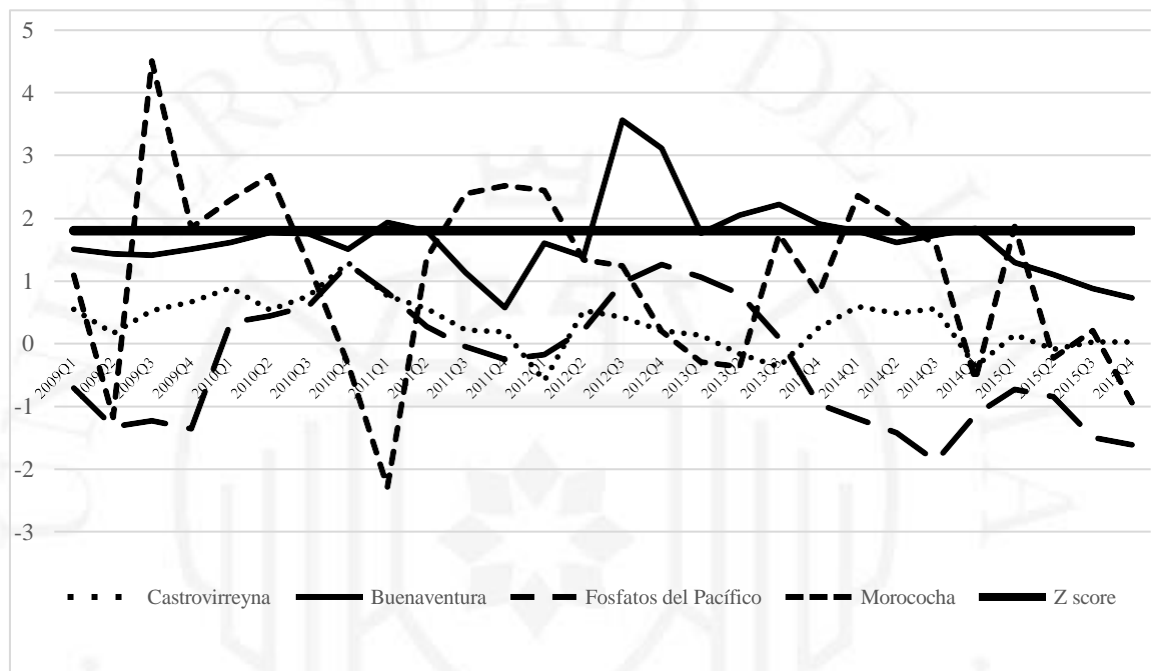
Nota. Resultados obtenidos a través del cálculo de la fórmula propuesta por Altman (1983).

Para el modelo de Análisis Discriminante Múltiple, Altman (1983) propone 3 zonas de clasificación: zona segura, zona de gris y zona peligro. Del análisis realizado, se sacó el

promedio de cada Z score por empresa para obtener una única respuesta de clasificación. Aquellas que pertenecen a la zona de peligro, poseen un Z Score por debajo de 1.8, se considerarán como empresas con fragilidad financiera; en consecuencia, las empresas mineras Castrovirreyna, Buenaventura, San Ignacio de Morococha y Fosfatos del Pacífico se encuentran en rango de zona de peligro. Estas recibirán la clasificación de “Frágiles”.

Figura 3.1

Mineras clasificadas en zona de peligro



En la gráfica analizamos aquellas empresas con menor Z score de los periodos en análisis y se puede observar que las 4 mineras clasificadas como “Frágiles” se encuentran por debajo del límite de la zona de peligro del modelo de Altman. En la mayoría de los trimestres, las empresas han estado por debajo del límite de 1.8. Con respecto al año 2009, la crisis de hipotecas de Estados Unidos repercutió en que la demanda de los minerales disminuye; como consecuencia, en el segundo trimestre del 2009 observamos que el Z score de ese periodo se redujo en gran cantidad, y las empresas que sufrieron un impacto significativo son Castrovirreyna, Fosfatos del Pacífico y Compañía Minera San Ignacio de Morococha. Cabe resaltar que, durante el primer y segundo trimestre, se registró un retroceso de exportaciones de aproximadamente -6.6% (SUNAT, 2009). Seguidamente, a finales del 2010 y principios del 2011, todas las empresas presentan un Z score por debajo

del límite de zona de peligro, esto puede entenderse que aun estas no se recuperaban financieramente con los hechos que ocurrieron en los años anteriores. Para el 2012, ya se estaba teniendo una mejora en el mercado global con el auge del precio de los minerales y se puede observar que Buenaventura logra ubicarse por encima del límite, esto se debe a que los niveles de exportación de oro y plata aumentaron. Por otro lado, para Castrovirreyna, Fosfatos del Pacifico y Compañía Minera San Ignacio de Morococha, el nivel de Z score fue mejorando, pero no lo suficiente como para alcanzar una zona gris o segura. Con respecto a Fosfatos del Pacifico, la empresa por periodos ha logrado posicionarse por encima del límite del Z score en los años 2012 y 2014.

Tabla 3.2

Resultado final sobre probabilidad de las empresas mineras

Mineras	Z Score	Fragilidad Empresarial Estimada Altman	Fragilidad Empresarial sobre Ratio de Apalancamiento
Sociedad Minera Corona S.A.	5.17	No Frágil	Frágil
Southern Peru Copper Corporation - Sucursal Del Perú	4.36	No Frágil	Frágil
Castrovirreyna Compañía Minera S.A.	0.32	Frágil	Frágil
Shougang Hierro Perú S.A.A.	2.12	No Frágil	Frágil
Perubar S.A.	1.85	No Frágil	Frágil
Compañía de Minas Buenaventura S.A.A.	1.66	Frágil	Frágil
Nexa Resources Atacocha S.A.A.	4.76	No Frágil	No Frágil
Compañía Minera Santa Luisa S.A.	3.16	No Frágil	No Frágil
Sociedad Minera El Brocal S.A.A.	3.14	No Frágil	No Frágil
Fosfatos del Pacifico S.A.	1.05	Frágil	No Frágil
Minera Andina de Exploraciones S.A.A.	9.09	No Frágil	No Frágil

(continúa)

(continuación)

Mineras	Z Score	Fragilidad Empresarial Estimada Altman	Fragilidad Empresarial sobre Ratio de Apalancamiento
Minsur S.A.	4.23	No Frágil	No Frágil
Compañía Minera Poderosa S.A.	1.91	No Frágil	No Frágil
Compañía Minera San Ignacio de Morococha S.A.A.	0.29	Frágil	No Frágil
Sociedad Minera Cerro Verde S.A.A.	5.15	No Frágil	No Frágil
Volcan Compañía Minera S.A.A.	3.66	No Frágil	No Frágil

Se realizó la comparativa de los resultados del modelo desarrollado contra el ratio de apalancamiento de cada una de las empresas mineras. Con respecto a las empresas frágiles del modelo de Altman, se predijo erróneamente a Buenaventura y Fosfatos del Pacífico, puesto que el ratio de apalancamiento las clasifica como empresas sin fragilidad financiera. Por otro lado, las empresas que predijo erróneamente sin fragilidad financiera el modelo de Altman son Sociedad Minera Corona, Perubar, Minera Andina Exploraciones y Minsur.

Para el modelo de Regresión Logística se tiene como primera la variable dependiente que se divide en: 0 que es una empresa no frágil y 1 cuando una empresa es frágil. A través de un modelo de Regresión Logit econométrico, se tendrá como objetivo observar la significancia de las variables y la probabilidad que tienen las variables independientes sobre la variable dependiente.

Variable Dependiente

$S =$ 0: *Empresa No Frágil* 1: *Empresa Frágil*

Variables Independientes

$$CATAT = \frac{\text{Capital de trabajo}}{\text{Activos Totales}}$$

$$ACRPCR = \frac{\text{ActivoCirculante}}{\text{PasivoCirculante}}$$

$$UIACT = \frac{\text{Utilidad antes de Intereses antes impuesto}}{\text{Activos Totales}}$$

$$UTNAT = \frac{\text{Utilidad neta}}{\text{Activos Totales}}$$

$$DETAT = \frac{\text{Deuda Total}}{\text{Activo Total}}$$

$$PLPPATR = \frac{\text{Pasivo a Largo Plazo}}{\text{Patrimonio}}$$

Antes de estimar la regresión final con las probabilidades, se ejecutará una matriz de correlación, evaluando los ratios financieros en estudio para determinar la existencia de problema de multicolinealidad dentro de las variables de la muestra.

Figura 3.2

Matriz de correlación de ratios financieros del modelo Logit

	ACRPCR	CATAT	UIACT	UTNAT	DETAT	PLPATR
ACRPCR	1	-0.1511	0.1457	0.1249	-0.464	-0.0562
CATAT	-0.1511	1	-0.0288	-0.1054	0.6838	-0.0423
UIACT	0.1457	-0.0288	1	0.7238	-0.0261	0.6892
UTNAT	0.1249	-0.1054	0.7238	1	0.018	0.6583
DETAT	-0.464	0.6838	-0.0261	0.018	1	0.2329
PLPATR	-0.0562	-0.0423	0.6892	0.6583	0.2329	1

Nota. Resultado de matriz de correlación obtenido luego de procesar la data en Stata.

Al realizar la prueba para observar la matriz de correlación, no se encontró algún problema de multicolinealidad sobre las variables seleccionadas. Por lo cual, no se retira ninguna variable del modelo. Con las variables seleccionadas, se estimará el modelo de regresión logística para observar el efecto y la significancia de las variables.

Tabla 3.3*Regresión Logística*

S	Coef	Robust Std. Err.	z	P>z	(95% Conf. Inteeval)	
ACRPCR	-1.729132	0.4240805	-3.50	0.000	-2.315598	-0.6532331
UIACT	-12.26183	5.335716	-2.30	0.022	-22.71964	-1.804014
UTNAT	19.72594	4.551108	4.33	0.000	10.80594	28.64595
DETAT	10.67651	2.609448	4.09	0.000	5.562089	15.79094
PLPPATR	1.152222	1.085448	1.06	0.288	-0.9752173	3.279661
_cons	-3.987564	0.861184	-4.63	0.000	-5.675454	-2.299675

Nota. Resultado obtenido luego de procesar la data en Stata.

La variable PLPPATR que hace referencia a el indicador financiero Pasivo a largo plazo / Patrimonio supera el valor de terminar una variable significativa, puesto que cuenta con un P value superior al 5% para el modelo, entonces se quitará y se volverá a correr el modelo.

Tabla 3.4*Regresión Logística Final*

S	Coef	Robust Std. Err.	z	P>z	(95% Conf. Interval)	
ACRPCR	-1.498986	0.4314393	-3.47	0.001	-2.344592	-0.6533807
CATAT	4.166026	1.398532	2.98	0.003	1.424955	6.907098
UIACT	-9.984771	4.04642	-2.47	0.014	-17.91561	-2.053933
UTNAT	18.49361	3.941283	4.69	0.000	10.76884	26.21838
DETAT	11.90829	2.604422	4.57	0.000	6.803715	17.01286
_cons	-3.908444	0.8551035	-4.57	0.000	-5.584416	-2.232472

Nota. Resultado obtenido luego de procesar la data en Stata.

Una vez que se cuenta con las variables significativas, se procede a correr el comando *predict* para revisar el resultado de probabilidad que alguna empresa evaluada cuente con fragilidad empresarial.

Tabla 3.5

Resultados de comando predict


Mínera	Predicción	Real	Descripción
Nexa Resources Atacocha	0.6	1	Predicción se aproxima a No Frágil
Volcan	0.4	0	Predicción se aproxima a Frágil

Nota. Resultado de comando predict obtenido luego de procesar la data en Stata.

Al analizar el resultado del modelo, no se obtienen errores al predecir la fragilidad empresarial de las mineras. Sin embargo, la tabla de resultados, existen 2 compañías mineras donde el resultado no es del todo preciso, ya que se aproximan a un valor que no es el correcto. Para el caso de Atacocha, la realidad es que se encuentra en estado de fragilidad financiera y en la predicción, la minera tiende a un resultado de “no fragilidad”. Lo mismo para el caso de la minera Volcan, según el modelo, apunta a considerarse una empresa en fragilidad lo cual es incorrecto, puesto que, en la realidad, la minera no presenta fragilidad financiera. En conclusión, se toma como resultado a la minera Nexa Resources Atacocha como empresa No Frágil y a la empresa Volcan como Frágil.

Figura 3.3

Mineras con clasificación opuesta según Logit



En el gráfico podemos observar que, según el modelo Logit, la minera Nexa Resources Atacocha y Volcan, del 2014 al 2015, tuvieron una tendencia a la “no fragilidad” y a la “fragilidad” respectivamente. Es por ello, que el resultado no es del todo preciso para dichas mineras. Asimismo, para el caso de Atacocha, se observa que en el trimestre 2010q2 tuvo un indicador a la no fragilidad, puesto que la economía de importación internacional se fue recuperando por el aumento de demanda de los minerales. Posteriormente, para ambas empresas, se visualiza que a inicios del 2012 existe una baja demanda del principal importador (China), esto se debe a que la economía de este país pasó por un proceso de desaceleración y el auge del precio de los minerales llegó a su fin. En el trimestre 2014q2, Volcan tiende a acercarse a la fragilidad financiera porque la compañía decidió continuar con sus proyectos y actividades de exploración minera, por lo que los resultados finales no les favorecieron financieramente (Bolsa de Valores de Lima, 2014).

Tabla 3.6

Resultado final sobre probabilidad de las empresas mineras

Mineras	Fragilidad Empresarial Estimada Logit	Fragilidad Empresarial sobre Ratio de Apalancamiento
Castrovirreyna Compañía Minera S.A.	Frágil	Frágil
Shougang Hierro Perú S.A.A.	Frágil	Frágil
Compañía Minera San Ignacio de Morococha S.A.A.	Frágil	Frágil
Nexa Resources Atacocha S.A.A.	No Frágil	Frágil
Sociedad Minera Corona S.A.	Frágil	Frágil
Compañía Minera Poderosa S.A.	Frágil	Frágil
Volcan Compañía Minera S.A.A.	Frágil	No Frágil
Compañía Minera Santa Luisa S.A.	No Frágil	No Frágil
Sociedad Minera El Brocal S.A.A.	No Frágil	No Frágil
Sociedad Minera Cerro Verde S.A.A.	No Frágil	No Frágil
Southern Peru Copper Corporation - Sucursal Del Perú	No Frágil	No Frágil
Minera Andina de Exploraciones S.A.A.	No Frágil	No Frágil
Minsur S.A.	No Frágil	No Frágil

(continúa)

(continuación)

Mineras	Fragilidad Empresarial Estimada Logit	Fragilidad Empresarial sobre Ratio de Apalancamiento
Compañía de Minas Buenaventura S.A.A.	No Frágil	No Frágil
Perubar S.A.	No Frágil	No Frágil
Fosfatos del Pacifico S.A.	No Frágil	No Frágil

Seguidamente, para poder estimar el modelo de predicción de redes neuronales, se tendrán como nodos de entrada (Variables Independientes):

$$CATAT = \frac{\text{Capital de trabajo}}{\text{Activos Totales}}$$

$$ACRPCR = \frac{\text{Activo Circulante}}{\text{Pasivo Circulante}}$$

$$UIACT = \frac{\text{Utilidad antes de Intereses antes impuesto}}{\text{Activos Totales}}$$

$$UTNAT = \frac{\text{Utilidad neta}}{\text{Activos Totales}}$$

$$DETAT = \frac{\text{Deuda Total}}{\text{Activo Total}}$$

$$PLPATR = \frac{\text{Pasivo a Largo Plazo}}{\text{Patrimonio}}$$

Asimismo, como variable dependiente “s” se dividirá en dos escenarios:

$$S = \quad 0: \text{ Empresa No Frágil} \quad 1: \text{ Empresa Frágil}$$

Como ya se realizó la prueba de correlación, se conoce que no existen problemas de multicolinealidad. Por lo que se procede a empezar el modelo en R studio. Para este, se utilizaron 2 capas ocultas (6 y 3 neuronas) y una matriz de confusión que nos indicará nuestras predicciones en base a los errores obtenidos.

Se empieza por filtrar las columnas de nuestra data que se utilizarán en nuestro modelo y no se tomarán en cuenta las demás.

```
data_filtrada <- data[, c("Mineras", "t", "plppatr", "acrpcr", "uiact", "utnat", "detat",  
"catat", "s")]
```

Esa data filtrada debe pasar por un proceso de escalado, ya que con esto se asegura que todas las variables de la muestra contengan como resultado una media de cero y desviación estándar de uno mediante la fórmula:

$$\text{Valor Escalado} = \frac{\text{Valor Original} - \text{Media}}{\text{Desv. Estándar}}$$

Sanderson (2023) indica que es necesario la transformación de los datos para así mejorar el rendimiento del modelo, esto utilizando la herramienta `scale()`. Con lo mencionado, procedemos a utilizar el comando, utilizando solo las variables independientes del modelo.

```
data_filtrada_escalada <- data_filtrada  
data_filtrada_escalada[, c("plppatr", "acrpcr", "uiact", "utnat", "detat", "catat")] <-  
+ scale(data_filtrada[, c("plppatr", "acrpcr", "uiact", "utnat", "detat", "catat")])
```

Luego, comenzamos con el proceso de partición, esto se entiende de la siguiente manera: brindaremos al modelo un porcentaje de data que se denomina “conjunto de entrenamiento” y otro porcentaje que se denomina “conjunto de prueba”. Utilizamos el 85% para el conjunto de entrenamiento, debido a que nos brinda resultados más eficientes en el modelo. Asimismo, se verifica que se está utilizando data de las 16 mineras en ambos conjuntos mediante el comando `length(unique(...))`

```
entrenamiento <- createDataPartition(data_filtrada_escalada$Mineras, p = 0.85,  
list = FALSE)  
conjunto_entrenamiento <- data_filtrada_escalada[index, ]
```

```

conjunto_prueba <- data_filtrada_escalada[-conjunto_entrenamiento, ]
length(unique(conjunto_entrenamiento$Mineras))
length(unique(conjunto_prueba$Mineras))

```

Al utilizar el comando `length(unique())`, nos arroja [1] 16, por lo que el modelo, en ambos conjuntos, está utilizando correctamente data de las 16 mineras.

Después de implementar los conjuntos de entrenamiento, se entrena al modelo utilizando la fórmula principal, que relaciona las variables dependientes e independientes. Se realiza esto para luego generar el modelo y así visualizar la estructura que posee nuestra red neuronal (capas, conexiones y pesos).

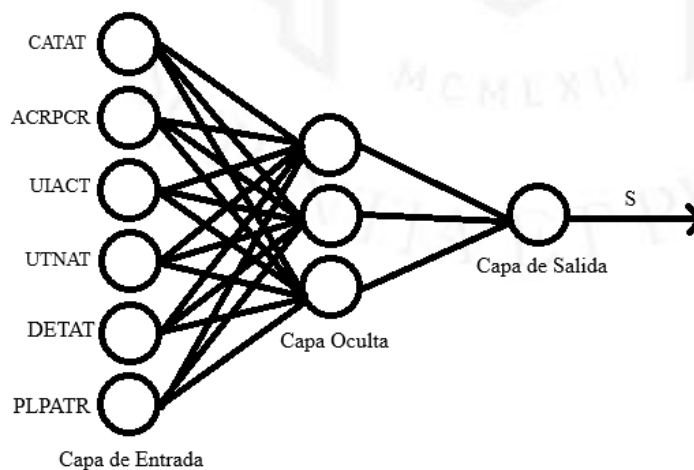
```

formula_principal <- as.formula("s ~ plppatr + acrprcr + uiact + utnat + detat +
catat")
modelo_redneuronal <- neuralnet(
formula,
data = conjunto_entrenamiento,
hidden = c(6, 3),
linear.output = FALSE )
plot(modelo_redneuronal)

```

Figura 3.4

Red Neuronal Mineras



Nota. Elaboración propia. Imagen adaptada del resultado obtenido en Rstudio.

Por último, se solicita al modelo la matriz de confusión, en esta matriz nos indicará dos escenarios como error que harán referencia a un falso positivos y un falso negativo. Aquellos que se obtengan como un falso positivo representan los casos en el que el modelo nos indica fragilidad cuando en realidad no son frágiles y los falsos negativos tienen el mismo sentido, pero cuando el modelo nos indica “no frágil”.

```

predicciones <- predict(modelo_redneuronal, conjunto_prueba)

prediccion_resultado <- ifelse(predicciones_red > 0.5, 1, 0)

diferencias <- data.frame(Mineras = conjunto_prueba$Mineras, Predicted =
prediccion_resultado)

matriz_confusion <- table(Predicted = prediccion_resultado, Actual =
conjunto_prueba$s)

```

Tabla 3.7

Matriz de confusión

Predicción/ Data empírica	No Frágil	Frágil
No frágil	39	0
Frágil	1	24

Nota. Resultado de matriz de confusión obtenidos luego de procesar la data en Rstudio.

Adicional a la matriz de confusión, se puede solicitar al modelo que nos indique específicamente cual es el falso positivo de la matriz.

Tabla 3.8

Tabla de Falsos Errores

Minera	Trimestre	Predicción	Real	Tipo
Minera Andina Exploraciones	2011q4	1	0	Falso Positivo

Nota. Resultado de falsos errores obtenidos luego de procesar la data en Rstudio.

Como resultado, podemos decir que nuestra matriz de confusión posee una precisión del 98.41%, ya que solo tuvo un error entre 128 observaciones. Sin embargo, al pasar estos resultados al panorama general, la eficiencia del uso de redes neuronales es de un 100%, puesto que al tener solo un trimestre como falso positivo no determina la fragilidad financiera en conjunto.

Tabla 3.9*Resultado final sobre probabilidad de las empresas mineras Red Neuronal*

Mineras	Fragilidad Empresarial Estimada Red Neuronal	Fragilidad Empresarial sobre Ratio de Apalancamiento
Castrovirreyna Compañía Minera S.A.	Frágil	Frágil
Shougang Hierro Perú S.A.A.	Frágil	Frágil
Compañía Minera San Ignacio de Morococha S.A.A.	Frágil	Frágil
Nexa Resources Atacocha S.A.A.	Frágil	Frágil
Sociedad Minera Corona S.A.	Frágil	Frágil
Compañía Minera Poderosa S.A.	Frágil	Frágil
Volcan Compañía Minera S.A.A.	No Frágil	No Frágil
Compañía Minera Santa Luisa S.A.	No Frágil	No Frágil
Sociedad Minera El Brocal S.A.A.	No Frágil	No Frágil
Sociedad Minera Cerro Verde S.A.A.	No Frágil	No Frágil
Southern Peru Copper Corporation - Sucursal Del Perú	No Frágil	No Frágil
Minera Andina de Exploraciones S.A.A.	No Frágil	No Frágil
Minsur S.A.	No Frágil	No Frágil
Compañía de Minas Buenaventura S.A.A.	No Frágil	No Frágil
Perubar S.A.	No Frágil	No Frágil
Fosfatos del Pacífico S.A.	No Frágil	No Frágil

CONCLUSIONES

Se concluye que las compañías mineras tienen un comportamiento particular, puesto que estas pueden seguir operando incluso en situaciones de bajo desempeño financiero. Por otro lado, para el caso de empresas de otros sectores, si estas tuvieran las mismas razones financieras que una empresa del sector minero, por lo general, ya estarían declaradas en bancarrota o quiebra.

El objetivo principal fue determinar qué modelo de predicción proporcionaba la probabilidad más exacta. Para lograr dicho objetivo, se tuvo que identificar las variables específicas que nos ayudarían a obtener los resultados más precisos en las metodologías de predicción de quiebra evaluadas.

Dentro de los resultados obtenidos, existen distintos grados de eficiencia para cada modelo en estudio. El modelo de Análisis Discriminante Múltiple (ADM) obtuvo un 62.5% de grado de eficiencia, puesto que predijo que de la muestra existen cuatro empresas que cuentan con fragilidad empresarial y doce empresas que no. Seguidamente, el modelo Logit obtuvo un 87.5% de grado de eficiencia, ya que tuvo dos errores en la predicción al tomar como empresa “frágil” a una “no frágil” y viceversa. Por último, el modelo de redes neuronales obtuvo un 100% de grado de eficiencia al predecir correctamente la fragilidad de las empresas. En consecuencia, se reafirma la hipótesis principal, asegurando que el modelo de Redes Neuronales es el que presenta un mayor grado de acierto sobre la muestra y el modelo que presenta mayor inexactitud es el modelo planteado por Altman (1983).

El modelo de Redes Neuronales demuestra la capacidad de poder capturar relaciones complejas de predicción con las razones financieras de las empresas del sector minero, por lo que la investigación contribuye con un modelo de grado de eficiencia alta cuyo propósito es la prevención de fragilidad empresarial. Asimismo, el modelo de Redes Neuronales identifica que, a pesar de que el modelo de Altman (1983) es uno de los más estudiados y utilizados en distintos sectores, para las empresas del sector minero no logra determinar una clasificación exacta de aquellas empresas que presentan o no fragilidad

financiera, esto se debe a las variables que se proponen en la ecuación, lo que limita la capacidad de predicción del modelo.



RECOMENDACIONES

Para trabajos posteriores, se sugiere tener en cuenta el comportamiento diferenciado que posee el sector, esto se debe a factores externos que impactan significativamente, como aspectos sociales, cambios regulatorios, contextos macroeconómicos u otros elementos difíciles de predecir. Además, se recomienda utilizar un periodo de investigación en el que hayan ocurridos eventos de alcance global, como crisis económicas o conflictos sociales, con la finalidad de que se pueda realizar el análisis comparativo respectivo de los resultados basados en estos escenarios. Es importante considerar que estas circunstancias en investigaciones futuras pueden proponer un valor agregado sobre los efectos de distintas situaciones que una empresa presencia, para poder así analizar con mayor precisión el comportamiento financiero del sector.

Asimismo, se recomienda optar por emplear el modelo de Redes Neuronales para la estimaciones futuras, puesto que proporciona una alta precisión en la estimación de resultados e identifica patrones que aquellos modelos pasados no logran capturar. Para realizar un análisis comparativo de modelos de predicción de quiebra, es pertinente que se elijan metodologías que fueron propuestas en distintos momentos históricos, con el fin de tener una mayor perspectiva de evolución de cada propuesta planteada y un trabajo estadísticamente sólido.

Finalmente, para estudios posteriores, en el caso peruano, se sugiere utilizar empresas mineras que se encuentren listadas en la Bolsa de Valores de Lima, puesto que el alcance de información financiera histórica trimestral se obtiene con mayor facilidad.

REFERENCIAS

- Altman, E. I. (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., Danovi, A., & Falini, A. (2013). Z-score models application to Italian companies subject to extraordinary administration. *Journal Of Applied Finance*, 23(1), 24-37.
- Altman, E. I., Marco, G., & Varetto, F. (1994). Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience). *Journal of Banking & Finance*, 18(3), 505–529. [https://doi.org/10.1016/0378-4266\(94\)90007-8](https://doi.org/10.1016/0378-4266(94)90007-8)
- Banco Central de Reserva del Perú. (2009). *En primer trimestre cayeron los volúmenes de exportaciones e importaciones*. <https://www.bcrp.gob.pe/docs/Transparencia/Notas-Informativas/2009/Nota-Informativa-039-2009-BCRP.pdf>
- Banco Central de Reserva del Perú. (2009). *Notas de Estudios Económicos del BCRP*. <https://www.bcrp.gob.pe/docs/Publicaciones/Notas-Estudios/2009/Nota-Estudios-22-2009.pdf>
- Beaver, W. H. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research*, 4, 71–111. <https://doi.org/10.2307/2490171>
- Bermeo Chiriboga, Daniela C., & Armijos Cordero, Johanna C. (2021). Bankruptcy prediction by the Z2 Altman model around construction companies of residential buildings in Azuay province. *Revista Economía y Política*, (33), 48-63. Epub 15, 2021. <https://doi.org/10.25097/rep.n33.2021.03>
- Bianco, A. M. and Martinez, E. (2009). Robust testing in the logistic regression model. *Computational Statistics and Data Analysis*, 53, 4095-4105.
- Bolsa de Valores de Lima. (2014). *Memoria Anual - Parte I*. <https://documents.bvl.com.pe/eeff/CM0001/20150326220801/MECM00012014A IA01.PDF>
- Chocce, G. A. R., Palma, Á. B., González, P. A., Aguirre, N. A., Vega, P. L., & Carrazana, J. M. (2002, June). Modelos de clasificación y predicción de quiebra de empresas: Una aplicación a empresas chilenas. *In Forum empresarial* (Vol. 7, No. 1 Verano, pp. 2-20).

- Chung, K. C., Tan, S. S., & Holdsworth, D. K. (2008). Insolvency prediction model using multivariate discriminant analysis and artificial neural network for the finance industry in New Zealand. *International journal of business and management*, 39(1), 19-28.
- Coaquira Jahuira, K., Chávez Cuadros, E. X., & Jalk Palma, W. H. (2021). Análisis de la liquidez y solvencia: su repercusión sobre la Gestión Financiera, caso Compañía Minera La Poderosa y Subsidiaria. *Revista De Investigación Valor Contable*, 8(1), 34 - 40. <https://doi.org/10.17162/rivc.v8i1.1601>
- Collins, E., Ghosh, S., & Scofield, C. L. (1988). An application of a multiple neural network learning system to emulation of mortgage underwriting judgements. *In ICNN* (pp. 459-466).
- Dutta, S., & Shekhar, S. (1988). Bond rating: a non-conservative application of neural networks. *In IEEE Int Conf on Neural Networks* (pp. 443-450). Publ by IEEE.
- Efrim Boritz, J., & Kennedy, D. B. (1995). Effectiveness of neural network types for prediction of business failure. *Expert Systems with Applications*, 9(4), 503-512. doi:10.1016/0957-4174(95)00020-8
- Etheridge, H. L., & Sriram, R. S. (1997). A comparison of the relative costs of financial distress models: artificial neural networks, logit and multivariate discriminant analysis. *Intelligent Systems in Accounting, Finance & Management*, 6(3), 235-248.
- Fattouh, B., Pisicoli, B., & Scaramozzino, P. (2024). Debt and financial fragility: Italian non-financial companies after the pandemic. *Economic Modelling*, 131, 106628.
- Fernández-Gámez, M. Á., Cisneros-Ruiz, A. J., & Callejón-Gil, Á. (2016). Applying a probabilistic neural network to hotel bankruptcy prediction. *Tourism & Management Studies*, 12(1), 40-52.
- Gentry, J. A., Newbold, P., & Whitford, D. T. (1985). Classifying bankrupt firms with funds flow components. *Journal of Accounting research*, 146-160. doi:10.2307/2490911
- Glave, M. (2007). La minería peruana: lo que sabemos y lo que aún nos falta por saber. 52053, 135-181.
- Grice Jr, J. S., & Dugan, M. T. (2003). Re-estimations of the Zmijewski and Ohlson bankruptcy prediction models. *Advances in Accounting*, 20, 77-93. doi:10.1016/S0882-6110(03)20004-3 doi:10.1016/S0882-6110(03)20004-3.
- Horobet, A., Curea, S. C., Smedoiu Popoviciu, A., Botoroga, C. A., Belascu, L., & Dumitrescu, D. G. (2021). Solvency risk and corporate performance: A case study on European retailers. *Journal of Risk and Financial Management*, 14(11), 536.

- Hosmer, D. W., Jr., and S. Lemeshow. 1980. Goodness-of-fit tests for the multiple logistic regression model. *Communications in Statistics—Theory and Methods* 9: 1043–1069
- Huo, Y., Chan, L. H., & Miller, D. (2024). Bankruptcy Prediction for Restaurant Firms: A Comparative Analysis of Multiple Discriminant Analysis and Logistic Regression. *Journal of Risk and Financial Management*, 17(9), 399.
- Inam, F., Inam, A., Mian, M. A., Sheikh, A. A., & Awan, H. M. (2018). Forecasting Bankruptcy for organizational sustainability in Pakistan. *Journal of Economic and Administrative Sciences*. 35(3), 183-201. doi:10.1108/jeas-05-2018-0063
- Jaffari, A. A., & Ghafoor, Z. (2017). Predicting corporate bankruptcy in Pakistan a comparative study of multiple discriminant analysis (MDA) and logistic regression. *Research Journal of Finance and Accounting*, 8(3), 81-100.
- Johnson, C. G. (1970). Ratio Analysis and the prediction of firm failure. *The Journal of Finance*, 25(5), 1166–1168. doi:10.1111/j.1540-6261.1970.tb00879.x
- Joy, M.O. and J.O. Tollefson, 1975, On the Financial Applications of Discriminant Analysis, *Journal of Financial and Quantitative Analysis*, 10 (5), 723-739.
- Khawaja, M. J. (2023). Predicting financial failure using altman’s z-score model: evidence from commercial banks in pakistan. *Annals of Social Sciences and Perspective*, 4(1), 91-102.
- Kim, H., Cho, H., & Ryu, D. (2022). Corporate bankruptcy prediction using machine learning methodologies with a focus on sequential data. *Computational Economics*, 59(3), 1231-1249. doi:10.1007/s10614-021-10126-5
- Lee, S., & Choi, W. S. (2013). A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis. *Expert Systems with Applications*, 40(8), 2941–2946. doi:10.1016/j.eswa.2012.12.009
- Leshno, M., & Spector, Y. (1996). Neural network prediction analysis: The bankruptcy case. *Neurocomputing*, 10(2), 125-147.
- 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, 3507-3516. doi: 10.1016/j.neucom.2009.02.018.
- Mihalovič, M. (2016). Performance Comparison Of Multiple Discriminant Analysis And Logit Models In Bankruptcy Prediction. *Economics and Sociology*, 9(4), 101-118. doi: 10.14254/2071-789X.2016/9-4/6.
- Ministerio de Comercio Exterior y Turismo. (2011). *Evolución de las Exportaciones – Noviembre* 2011

https://cdn.www.gob.pe/uploads/document/file/471838/RM_Expo_Noviembre_2011.pdf

- Ministerio de Energía y Minas. (2011). *Boletín Estadístico Minero 07-2011*. <https://cdn.www.gob.pe/uploads/document/file/2068383/BEM%2007-2011.pdf.pdf?v=1628449128>
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, 109-131. doi:10.2307/2490395
- Odom, M. D., & Sharda, R. (1990, June). A neural network model for bankruptcy prediction. In 1990 IJCNN International Joint Conference on neural networks (pp. 163-168). *IEEE*. doi:10.1109/IJCNN.1990.137710
- Pilch, B. (2021). An analysis of the effectiveness of bankruptcy prediction models—an industry approach. *Folia Oeconomica Stetinensia*, 21(2), 76-96. doi:10.2478/fofi-2021-0017
- Podobnik, B., Horvatic, D., Petersen, A. M., Urošević, B., & Stanley, H. E. (2010). Bankruptcy risk model and empirical tests. *Proceedings of the National Academy of Sciences*, 107(43), 18325-18330. doi:10.1073/pnas.101194210
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>
- Reisz, A. S., & Perlich, C. (2007). A market-based framework for bankruptcy prediction. *Journal of financial stability*, 3(2), 85-131. doi:10.1016/j.jfs.2007.02.001
- Riedmiller M. (1994) Rprop - Description and Implementation Details. Technical Report. University of Karlsruhe.
- Rumelhart D., Geoffrey E Hinton, and Ronald J Williams. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088):533-536, 1986.
- Sanderson, S. P., II. (2023). *Mastering data transformation with the scale() function in R*. *R-Bloggers*. <https://www.r-bloggers.com/2023/08/mastering-data-transformation-with-the-scale-function-in-r/>
- Stoltzfus, J. C. (2011). Logistic Regression: A Brief Primer. *Academic Emergency Medicine*, 18(10), 1099-1104. doi:10.1111/j.1553-2712.2011.01185.x
- Superintendencia Nacional de Administración Tributaria SUNAT. (2009). *Sunat destacó labor de principales deudores tributarios en cumplimiento de pago de deudas*. <https://www.sunat.gob.pe/salaprensa/2009/diciembre/np091209a.htm>


- Terzo, G. (2022). *La minería metálica, un punto brillante en Perú en medio del cambio de Gobierno*. <https://www.ciat.org/la-mineria-metalica-un-punto-brillante-en-peru-en-medio-del-cambio-de-gobierno/>
- Theodossiou, P. (1991). Alternative models for assessing the financial condition of business in Greece. *Journal of Business Finance & Accounting*. doi:10.1111/j.1468-5957.1991.tb00233.
- Tsai, C. F., & Wu, J. W. (2008). Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert systems with applications*, 34(4), 2639-2649.
- Tseng, F. M., & Hu, Y. C. (2010). Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks. *Expert systems with applications*, 37(3), 1846-1853. doi:10.1016/j.eswa.2009.07.081
- Wilson, R. L., & Sharda, R. (1994). Bankruptcy prediction using neural networks. *Decision Support Systems*, 11(5), 545–557. doi:10.1016/0167-9236(94)90024-8
- Wirgård, Wiklund, J. (2022). Predicting company bankruptcy using artificial neural networks. Visualization and ranking of key features.
- Zelenkov, Y., & Volodarskiy, N. (2021). Bankruptcy prediction on the base of the unbalanced data using multi-objective selection of classifiers. *Expert Systems with Applications*, 185, 115559. doi:10.1016/j.eswa.2021.115559

BIBLIOGRAFÍA

Altman, E.I. (1983). *Corporate Financial Distress. A Complete Guide to Predicting, Avoiding, and Dealing with Bankruptcy*. Wiley.

Altman, E. I., & Hotchkiss, E. (1993). *Corporate financial distress and bankruptcy* (Vol. 1998, pp. 105-110). New York: John Wiley & Sons.

Wooldridge, J. (2009). *Introductory Econometrics 4th ed.*, South-Western Cengage Learning.



Miguel Alonzo Cruz Jáuregui

COMPARATIVA DE MODELOS DE PREDICCIÓN DE QUIEBRA: UNA APLICACIÓN PARA EL SECTOR MINERO COMPRENDIDO...

 Evaluación Tesis

 Investigación

 Universidad de Lima

Detalles del documento

Identificador de la entrega

trn:oid:::1:3216529443

Fecha de entrega

14 abr 2025, 11:22 a.m. GMT-5

Fecha de descarga

14 abr 2025, 11:26 a.m. GMT-5

Nombre de archivo

A1-TESIS-20151795-20173817_SUSTENTACIO_N.pdf

Tamaño de archivo

811.7 KB

47 Páginas

10.918 Palabras

61.564 Caracteres




11% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report


- Bibliography

Top Sources

- 10%  Internet sources
- 6%  Publications
- 5%  Submitted works (Student Papers)

Integrity Flags

1 Integrity Flag for Review

-  **Hidden Text**
4 suspect characters on 1 page
Text is altered to blend into the white background of the document.

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 10% Internet sources
- 6% Publications
- 5% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	hdl.handle.net	2%
2	Internet	repositorio.unac.edu.pe	<1%
3	Internet	www.coursehero.com	<1%
4	Internet	dspace.ucuenca.edu.ec	<1%
5	Internet	idus.us.es	<1%
6	Internet	icons8.com.br	<1%
7	Student papers	UNILIBRE	<1%
8	Internet	www.minem.gob.pe	<1%
9	Internet	repositorio.uchile.cl	<1%
10	Internet	repositorio.ulima.edu.pe	<1%
11	Internet	repositorio.unal.edu.co	<1%

12	Student papers	Universidad ESAN -- Escuela de Administración de Negocios para Graduados	<1%
13	Student papers	Universidad de Lima	<1%
14	Internet	cdn.www.gob.pe	<1%
15	Internet	wiredspace.wits.ac.za	<1%
16	Internet	documentop.com	<1%
17	Internet	repositorio.uniandes.edu.co	<1%
18	Student papers	Universidad Anahuac México Sur	<1%
19	Student papers	Universidad San Ignacio de Loyola	<1%
20	Internet	repository.unab.edu.co	<1%
21	Internet	www.emis.com	<1%
22	Publication	Luis Bernardo Tonon Ordóñez, Iván Felipe Orellana Osorio, Luis Gabriel Pinos Luz...	<1%
23	Internet	repository.cesa.edu.co	<1%
24	Internet	ri.uaemex.mx	<1%
25	Internet	www.biblioteca.uma.es	<1%

26	Student papers	National Economics University	<1%
27	Student papers	Instituto Superior de Formacion Docente Salomé Urenq	<1%
28	Internet	www.mdpi.com	<1%
29	Internet	ndltd.ncl.edu.tw	<1%
30	Internet	www.gacetajuridica.com.pe	<1%
31	Student papers	Bridgepoint Education	<1%
32	Internet	econpapers.repec.org	<1%
33	Internet	www.aai.com.pe	<1%
34	Student papers	Universidad de Málaga - Tii	<1%
35	Internet	addi.ehu.es	<1%
36	Internet	fdocuments.us	<1%
37	Internet	journals.unizik.edu.ng	<1%
38	Internet	vsip.info	<1%
39	Internet	www.dspace.unitru.edu.pe	<1%

40

Internet

www.grafiati.com

<1%