



EMPRESAS EXITOSAS QUE INTEGRARAN EL IPC DE MÉXICO: UNA CLASIFICACIÓN MEDIANTE REGRESIÓN LOGÍSTICA Y REDES NEURONALES ARTIFICIALES

Área de investigación: Finanzas

Lázara Yamila Castillo García

Centro Universitario de Ciencias Económico Administrativas
Universidad de Guadalajara
México
lazara.castillo@alumnos.udg.mx

Moisés Alejandro Alarcón Osuna

Centro Universitario de Ciencias Económico Administrativas
Universidad de Guadalajara
México
moises.alarcon@cucea.udg.mx



EMPRESAS EXITOSAS QUE INTEGRARÁN EL IPC DE MÉXICO: UNA CLASIFICACIÓN MEDIANTE REGRESIÓN LOGÍSTICA Y REDES NEURONALES ARTIFICIALES

Resumen

El siguiente trabajo tiene el propósito de identificar el modelo que mejores resultados ofrece en la predicción del éxito empresarial, que sean determinantes para lograr el éxito financiero de las empresas que cotizan en la Bolsa Mexicana de Valores (BMV), en específico las que integran el Índice de Precios y Cotizaciones (IPC). Para lograr los objetivos propuestos se hace uso del modelo *Logit*, el Perceptron Multi-Capa (MLP) y el K- Vecinos. Para ello se consideran 30 empresas que pertenecen al índice, exceptuando las financieras, determinando para cada empresa el número de razones financieras, para el periodo comprendido entre 2010 y 2020. Se considera como criterios de éxito financiero a aquellas empresas que crean valor teniendo crecimiento consecutivo por dos años en las utilidades netas y el precio de las acciones del mercado. Las diversas implementaciones de las técnicas y modelos para el presente estudio se realizan utilizando el lenguaje de programación R. Los resultados obtenidos muestran que los modelos Perceptron Multi-Capa (MLP) y el K- Vecinos son los que mejores resultados ofrecen para la predicción del éxito financiero de las empresas que conforman el Índice de Precios y Cotizaciones de México.

Palabras clave: éxito empresarial, Índice de Precios y Cotizaciones, razones financieras, *Logit*, Perceptron Multi-Capa (MLP), K- Vecinos.

Introducción

El diagnóstico financiero constituye una herramienta efectiva para la evaluación del desempeño económico de una empresa a lo largo de un ejercicio específico, permitiendo la comparación con otras entidades del mismo sector, con características comunes y con una gestión eficaz, partiendo de que los objetivos de establecer relaciones cuantitativas que nacen del proceso de toma de decisiones de la gerencia sobre los datos contables analizados e interpretados con anterioridad. El análisis

financiero es útil para evaluar el desempeño económico de una empresa, detectar los problemas y lograr su corrección. (Rosillón & Alejandra, 2009).

La economía mexicana a raíz de las crisis crediticias pasadas (2008, 2009) y la recesión sostenida ha dificultado la situación para los mercados bursátiles, cabe destacar que los intentos para predecir dificultades financieras no son recientes, han llamado la atención por más de medio siglo (Anandarajan et al., 2001). Destacando que las empresas del sector comercial son muy vulnerables a los cambios y condiciones desfavorables del mercado (Gu, 2002). Según Kin y Gu (2006) tanto la poca capacidad de generar valor como la quiebra financiera en el sector de la BMV demanda modelos eficientes de predicción del desempeño financiero (Kin y Gu, 2006 a y b). Pero el enfoque del desempeño financiero basado en quiebras requiere de un análisis a largo plazo, un proceso continuo, por lo que no es un evento inmediato, además de esto el enfoque del presente trabajo predice el desempeño financiero de las empresas permitiendo corregir las deficiencias de las mismas cuando se pronostica un retroceso o se pretende llegar a un mejor desempeño, el enfoque en el desempeño de empresas financieramente exitosas también ayuda a determinar en qué medida la empresa está sujeta a recibir crédito y el establecimiento de garantías.

Existen muchos estudios para la medición del desempeño financiero empresarial pero los mismos no comparten las características propias del entorno mexicano (Morales, 2007). El estudio empírico de Beaver de 1966 le permitió medir la liquidez de las empresas mediante un análisis univariable, demostrando que las razones financieras logran medir el desempeño financiero de la empresa de manera eficiente. (Beaver, 1966).

Los estudios más significativos realizados en México para medir el desempeño empresarial son: Metodología paramétrica para la calificación y aprovisionamiento de la cartera hipotecaria en el año de 1997 (Pelayo, 1997), ¿Previeron las empresas mexicanas la crisis financiera de 1995-1996?, (Watkins, 2003), Aplicación del modelo Altman para empresas del mercado bursátil mexicano: un análisis comparativo de empresas exitosas y no eficientes en los 90's [sic] (Altman, Seudónimo). El modelo de alerta temprana para evaluar el desempeño financiero de las empresas mexicanas (comparación entre los enfoques multivariado y de creación de valor) Tamanara

(Seudónimo), Bases para la construcción de un modelo de predicción del éxito en las Pymes”, (Lozano, 2002), todos estos estudios utilizando razones financieras abarcaron periodos de tiempos muy restringidos y de ellos los que se refieren a empresas exitosas lo hacen desde estudios cualitativos y no cuantitativos. Luego Morales en el 2007 realiza una investigación enfocada a lograr una correcta selección de los ratios que reflejan el desempeño financiero empresarial para la realidad mexicana y a raíz de una revisión extensa de literatura afirma que los tres estudios efectuados con una orientación hacia empresas exitosas son el de Paul J. Fitzpatrick en EEUU por el periodo de 1920-1929, el de Robert O. Edmister EEUU en 1972 y el de Altman (Seudónimo) en México 1993-1998, (Morales, 2007).

Justamente la crisis financiera que ha provocado la pandemia de COVID-19 a nivel global ha devuelto el interés por la investigación sobre el éxito empresarial. El problema subyacente es que, como lo expreso el economista de Harvard, Lawrence Summers citado en Coy (2020), “el tiempo económico se detuvo debido a la pandemia, pero el reloj financiero sigue avanzando” (s/n). Los intereses y pagos de renta continúan, pero la capacidad para cubrirlos se termina (ibídem, 2020). La realidad hace que se dificulte no solo para las pequeñas y medianas empresas sino también para aquellas con solidez económica como las 144 empresas enlistadas en la bolsa mexicana, de las que solo 30 han aumentado su valor de mercado durante la pandemia (Editores, 2020).

Sin embargo, existen ciertos modelos y técnicas de predicción, científicamente estudiadas y evolucionadas, que pueden ser empleadas en el entorno empresarial mexicano con la intención de que inversores, empresarios y otros interesados, mejoren la toma de sus decisiones y logren pronosticar el éxito o no éxito de las empresas. Por lo que cabe elaborar la siguiente pregunta de investigación: ¿Cuál de los modelos aplicados (Modelo de Regresión Logística, Perceptron Multi-Capa (MLP) y K- Vecinos) es el que mejores resultados ofrece en la predicción del éxito financiero empresarial de las empresas integran el IPC de México?

Anticiparse a pronosticar el éxito de manera eficiente y efectiva resulta complicado, por tanto, la descripción de su proceso y desarrollo mediante modelos predictivos son cuestiones relevantes desde el punto de vista académico y profesional. Por lo que el objetivo del presente

trabajo es aplicar los tres modelos; Redes neuronales artificiales (Perceptron Multi-Capa (MLP) y el K- Vecinos) y el Modelo de Regresión Logística, para determinar cuál tiene la mejor predicción de las empresas exitosas y no exitosas que cotizan en la Bolsa Mexicana de Valores e integran el Índice de Precios y Cotizaciones (IPC).

Para lograr dicha tarea, se toman las empresas que conforman el Índice de Precios y Cotizaciones (IPC) por la disponibilidad de datos y ser el indicador oficial de la evolución del mercado accionario, ya que busca medir el rendimiento de las acciones de mayor tamaño y liquidez listadas en la Bolsa Mexicana de Valores y su importancia se debe a que es la referencia de la gran mayoría de participantes del mercado, incluyendo a las empresas locales e internacionales, con la finalidad de seguir y medir el desempeño del mercado de valores mexicano.

Aunque existen trabajos que se refieren a la problemática de la desaparición de grandes empresas en México, pocos de ellos hablan del desarrollo de una metodología basada en redes neuronales que pueda evaluar el desempeño financiero, predecir el éxito y su opuesto. En consecuencia a lo reflejado se formula la siguiente hipótesis de investigación: Un modelo de Redes Neuronales Artificiales (RNA) es el que mejor precisión ofrece en la predicción del éxito empresarial, desde el punto de vista financiero, de las empresas que integran el IPC de México.

La variable tomada como dependiente es el éxito empresarial, se consideran como criterios de éxito financiero a aquellas empresas que crean valor teniendo crecimiento consecutivo por dos años en las utilidades netas y el precio de las acciones del mercado. Las variables independientes son los siguientes parámetros (ratios económicos) seleccionados:

- Capital de Trabajo/ Activo Total (WC/TA)
- Ganancias retenidas/ Activo Total (RE/TA)
- Ganancias antes de intereses e impuestos / Activos totales (EBIT/TA)
- Activo circulante / activo total (CA/TA)
- Activo corriente / pasivo corriente (CA/CL)
- Ingresos Netos / Activo Total (NI/TA)
- Ventas / Activo Total (SALE/TA)

- Precio/ Ventas (Prices/ Sales)
- Precio/valor contable (Price/Book)

El método empleado para lograr el objetivo de la investigación se centra en realizar un estudio investigativo mediante la implementación de técnica paramétrica *Logit*, Modelo Perceptron multicapa y Modelo *k*-vecinos, para determinar si una empresa es exitosa o no financieramente, se toma en consideración las razones financieras seleccionadas y la muestra de estudio (empresas que cotizan en la BMV, que conforman el IPC). El método utilizado es el experimental, la metodología comprende las etapas siguientes:

1. Revisión de literatura con enfoque en modelos de predicción financiera.
2. Conformación de la base de datos, compuesta por 30 que integran el IPC con la excepción de las financieras.
3. Obtención y determinación de las razones financieras que miden el desempeño empresarial en el periodo comprendido entre 2010-2020 con periodicidad anual.
4. Determinación de los indicadores financieros que miden el desempeño financiero empresarial por los accionistas para clasificar a las empresas exitosas y no exitosas.
5. Establecimiento de los criterios de entrada y salidas para la construcción de diferentes modelos (*Logit* y RNA)
6. Establecimiento de la arquitectura de la Red Neuronal Artificial.
7. Análisis de los resultados entre los diferentes modelos planteados, valorando la precisión en la predicción de los resultados.

Revisión de la literatura

Los estudios de predicción o clasificación de éxito financiero o fracaso por lo general se han realizado con datos de las empresas que cotizan en bolsa siendo estas las que están obligadas a publicar sus estados financieros, siendo estos necesarios para el cálculo de los ratios financieros que se usan en dichos modelos. Existe gran diversidad de opiniones en la literatura tanto en la elección de los ratios, como en la cantidad, y si es conveniente o no añadir variables descriptivas, no existiendo ninguna teoría económica que establezca un criterio único.

Dado a que los principales estudios para la investigación del desempeño financiero se han enfocado al fracaso empresarial y las mismas técnicas que se usan en la predicción de fracaso se usan a las de éxito, se realiza una revisión de la literatura que brevemente explique la evolución de dichos estudios.

El precursor de la investigación empírica del riesgo de quiebra y éxito empresarial fue Beaver (1966), quien utilizó métodos univariados basados en la comparación. Utilizó 30 razones financieras y 79 pares de empresas (fracaso / no fracaso). Las razones financieras se eligieron si cumplían con los siguientes criterios: uso amplio en la literatura, buen desempeño de su uso en investigaciones anteriores, la capacidad de las razones para definirse como elementos del flujo de efectivo. El mensaje esencial de su estudio fue que ignorar la magnitud del error de pronóstico, que “desecha” parte del contenido de información de las ganancias. (Raluca Badea & Matei, 2016). Una limitación del trabajo de Beaver se basa principalmente en la naturaleza univariante del modelo que desarrolló, la complejidad financiera de una empresa no se puede encerrar con una sola razón.

Existe un gran número de enfoques, pero los dos modelos más influyentes en el análisis de la información financiera son los de Edward I. Altman y J. Ohlson. Altman (1968) utiliza un análisis discreto múltiple para estimar un modelo llamado modelo de puntaje Z, que ha sido ampliamente utilizado por los departamentos de riesgo a nivel mundial, aplicado a diferentes contextos y sectores. Este método continúa efectivo para diferenciar entre empresas exitosas de las que van rumbo a la quiebra en términos financieros. El modelo se desarrolló primero utilizando como muestra empresas industriales, clasificadas como quebradas o no quebradas, considerando cinco variables relevantes; en términos de liquidez, rentabilidad, apalancamiento, solubilidad y ratios de actividad. (Raluca Badea & Matei, 2016). Este modelo fue utilizado y validado por Altman para predecir la quiebra de una muestra que constaba de 53 empresas en quiebra y 58 no quebradas, con una precisión de clasificación del 94%, pero estudios posteriores afirman que la precisión del modelo era solo el 70%.

Ohlson estimó durante el 1980 otro modelo influyente utilizando un enfoque binario *logit* basado en variables distintas de las utilizadas por Altman, agregando variables explicativas y aumento los datos para

mejorar el pronóstico, al igual que Altman su modelo fue para empresas manufactureras. Ambos estudios desarrollaron una puntuación para medir la probabilidad de incumplimiento de las empresas. Estas medidas se han convertido en fundamentales a la hora de evaluar el riesgo crediticio de distintas firmas. (Taurell & Augustsson, 2012). Ohlson logra reunir 105 firmas en quiebra y 2058 firmas no quebradas, elimina el emparejamiento de firmas en quiebra y supervivientes, que argumentó, era arbitraria y por lo tanto imprecisa para estimaciones acertadas.

La parte de emparejamiento es necesaria en el análisis de discriminación múltiple que usa Altman, pero no en el modelo *Logit* estático que usa Ohlson. Durante los últimos 50 años, tanto los autores como otros investigadores han realizado aportes a ambos modelos. En las últimas décadas se han realizado importantes contribuciones en las mejoras de las técnicas para la determinación del éxito empresarial. Dichas mejoras se han concretado en la investigación del diseño muestral, la selección de variables y la elección de técnicas estadísticas y computacionales.

Modelos estadísticos, Modelo ZETA por Altman, Haldeman y Narayanan (1977), fue realizado con datos de EE.UU. utilizados para investigar el periodo entre 1969- 1975, con una muestra de 53 empresas fracasadas y 58 sin fracasar y siete ratios financieros. El poder predictivo del modelo se redujo significativamente cinco años antes de 70% y 82% para empresas fallidas y no fallidas, respectivamente. Esta vigilancia destaca que las variables son irregulares en varios estudios. El estudio logró una mala clasificación del 7% para el error de tipo I y 3% mayor (es decir, 10%) tipo II error un año antes de Fracaso.

Tam and Kiang (1992) realizaron un Modelos de Redes Neuronales (RN) con múltiples alternativas: regresión, análisis discriminante, logística, k Vecino más cercano, con una selección de 19 ratios financieros (de los estados financieros de bancos), Informaron que, aunque las redes neuronales tuvieron un mejor desempeño que el análisis discriminante, las diferencias no siempre fueron significativas. En 2008 PCFMLC aplica Modelos estadísticos para la comparación del análisis discriminante múltiple, la regresión logística y *Hazard Model*, se examinaron 26 empresas en quiebra y 26 que no estaban en bancarrota y cotizan en Bursa Malasia, se vio el *Hazard Model*, para predecir el 94,9% y el 63,9%

de la estimación. El MDA un tipo de precisión global del 80,8 % modelo *Logit*, podría predecir correctamente 82.7%.

Desempeño financiero como muestra de éxito empresarial

Una definición interesante de desempeño financiero es la brindada por Evans y Lindsay (2008), estableciéndolo como los objetivos obtenidos a través del uso de razones financieras, para obtener utilidades necesarias y afrontar los desafíos de la economía que se presentan día a día. Según García (2017) se puede intuir que el desempeño financiero está definido como aquella actividad financiera que se lleva a cabo con el fin de alcanzar un logro, meta u objetivo (García, 2017). La rentabilidad y una situación financiera con solidez (desempeño financiero) son indicadores importantes del éxito logrado por una empresa. Por lo que el contar con información financiera y herramientas que apoyen la toma de decisiones se considera indispensable.

Clasificación de los modelos de predicción de éxito

Los modelos de predicción de éxito pueden clasificarse en dos categorías, en función del origen de la información que utilizan como input para realizar el análisis de insolvencia económica y según su propósito investigativo, en el primer caso lo clasifican en Aproximación con base contable, en el que se aplican métodos cuantitativos y cualitativos a la solvencia de la empresa, en el caso de la estimación a partir de fuentes alternativas y superiores usando la información del mercado.

En el segundo caso atendiendo a su propósito investigativo se dividen en tres grupos; primero los modelos teóricos, estos orientados a las causas de insolvencia, con base en la teoría, multivariantes y aplican técnicas estadísticas, el segundo grupo son los modelos estadísticos; se centran en los síntomas que produce la insolvencia los datos proceden de la contabilidad de las empresas son modelos univariantes o multivariantes y se guían por los modelos clásicos, y por último los modelos basados en inteligencia artificial se basan en los síntomas de insolvencia, los datos al igual proceden de la contabilidad de las compañías comúnmente son multivariantes, resultan del desarrollo tecnológico y dependen de la tecnología computacional. (Casarejos, 2016), (Escobar, 2002).

Metodología

Existe un gran número de literatura que abunda la creación de los modelos de predicción de éxito empresarial a partir de ratios económicos obtenidos de los datos contables financieros de las empresas, pero discrepante desde el punto de vista de la selección de los ratios, la cantidad de variables descriptivas, años de ejercicios de las empresas y los distintas técnicas y arquitecturas. Los ratios financieros, entre otros, miden la relación que existe entre dos cifras económicas o financieras de una empresa obtenidas de los estados financieros de esta. La comparación entre razones financieras de períodos distintos sirve además para detectar tendencias, determinar la eficiencia de la gestión empresarial, por lo que su estudio permite la anticipación a inconvenientes permitiendo la búsqueda de soluciones oportunas.

Con el objetivo principal de realizar una predicción lo más acertada posible sobre el éxito financiero, a nivel empresarial, sobre las empresas que conforman el IPC, en la BMV, se dispone a la implementación y de tres modelos matemáticos, Regresión Logística, Perceptron Multicapa y K- Vecinos más cercanos. Para el desarrollo del presente trabajo de se conformó una base de datos de 30 empresas pertenecientes al IPC que cotizan en la BMV, tomando un periodo de estudio comprendido entre 2010-2020 (10 años), es importante aclarar que durante todo el periodo de estudio todas las empresas no cotizaron en su totalidad en la BMV. Obteniendo un total de 299 datos de empresas.

Se seleccionaron un total de 9 razones financieras, calculadas a partir de información brindada por *Yahoo Finance*¹, que miden el desempeño empresarial en base a su clasificación, para el periodo de 2010-2020 con periodicidad anual. Para la clasificación de empresas exitosas y no exitosas, los indicadores tomados fueron la variación en el valor de la acción del mercado y la utilidad neta en los últimos 3 años. Se consideraron como empresas exitosas aquellas con ambas condiciones de desempeño financiero, variación positiva en el valor de la acción e utilidades netas en los últimos 2 años.

Las razones financieras para el estudio fueron:

1 Yahoo! Finance es una propiedad de medios que forma parte de Yahoo! Network, que, desde 2017, es propiedad de Verizon Media. Proporciona noticias financieras, datos y comentarios, incluidas cotizaciones de acciones, comunicados de prensa, informes financieros y contenido original.

Capital de Trabajo/ Activo Total (WC/TA)

El capital de trabajo evalúa la capacidad de una empresa para pagar sus pasivos corrientes con sus activos corrientes, lo que nos da una indicación de la salud financiera a corto plazo del sujeto, la capacidad para liquidar sus deudas en un año y la eficiencia operativa. (Fernando, 2021).

Ganancias retenidas/ Activo Total (RE/TA)

La división de las ganancias retenidas entre los activos totales es una relación que ayuda a medir la rentabilidad de los activos de una entidad. (Fernando, 2021).

Ganancias antes de intereses e impuestos / Activos totales (EBIT/TA)

El rendimiento de los activos totales (ROEA) es una relación que mide las ganancias de una empresa antes de intereses e impuestos (EBIT) en relación con sus activos totales. Se define como la relación entre los ingresos netos y los activos promedio totales, o la cantidad de ingresos financieros y operativos que recibe una empresa en un año financiero en comparación con el promedio de los activos totales de esa empresa (Fernando, 2021).

Activo circulante / activo total (CA/TA)

Este ratio ayuda a medir la liquidez de la empresa. Una empresa con un índice alto indica una alta liquidez y viceversa. Indica el alcance de los fondos totales invertidos con el propósito de capital de trabajo y arroja luz sobre la importancia de los activos corrientes de una empresa.

Activo corriente / pasivo corriente (CA/CL)

El índice de solvencia o razón corriente mide la capacidad de una empresa para pagar obligaciones a corto plazo (menor de un año). Dice a los inversores y analistas cómo una empresa puede maximizar los activos corrientes en su balance para satisfacer su deuda actual y otras cuentas por pagar. Como resultado de su cálculo se entiende que entre mayor sea el índice mejor es la capacidad de pago de sus obligaciones (Fernando, 2021).

Ingresos Netos / Activo Total (NI/TA)

El rendimiento de los activos (ROA) es un indicador de la rentabilidad de una empresa en relación con sus activos totales. Este indicador se considera un medidor de la eficacia en la gestión de la gerencia de la empresa para generar ganancias con los activos disponibles (Fernando, 2021).

Ventas / Activo Total (SALE/TA)

El índice de rotación de activos mide el valor de las ventas o los ingresos de una empresa en relación con el valor de sus activos. El índice de rotación de activos se puede utilizar como indicador de la eficiencia con la que una empresa utiliza sus activos para generar ingresos. Cuanto mayor sea el índice de rotación de activos, más eficiente será una empresa para generar ingresos a partir de sus activos. Por el contrario, si una empresa tiene un índice de rotación de activos bajo, indica que no está utilizando sus activos de manera eficiente para generar ventas (Fernando, 2021).

Precio/ Ventas (Prices/ Sales)

La relación precio-ventas muestra cuánto valora el mercado cada dólar de las ventas de la empresa. Esta relación puede ser eficaz para valorar acciones de crecimiento que aún no han obtenido beneficios o han sufrido un revés temporal (Fernando, 2021).

Precio/valor contable (Price/Book)

Las empresas utilizan la relación precio-valor contable (relación P / B) para comparar la capitalización de mercado de una empresa con su valor contable. Se calcula dividiendo el precio de las acciones de la empresa por acción por su valor en libros por acción (BVPS). El valor en libros de un activo es igual a su valor en libros en el balance general, y las empresas lo calculan compensando el activo con su depreciación acumulada (Fernando, 2021).

Modelos de predicción

En este apartado se realiza un análisis crítico de investigaciones anteriores y de fuentes con enfoques, teorías y modelos relacionados con el estudio del éxito empresarial, además de describir los modelos implementados y para la predicción del éxito empresarial.

Modelo logístico (Logit)

El análisis de regresión logística también se ha utilizado particularmente para investigar la relación entre la probabilidad de respuesta binaria u ordinal y las variables explicativas. Para la predicción de quiebras, la probabilidad de respuesta binaria suele ser la probabilidad predeterminada, mientras que se puede utilizar un gran número de variables explicativas. El método generalmente se ajusta a modelos de regresión logística lineal para datos de respuesta binaria u ordinal mediante el método de máxima verosimilitud (Hosmer y Lemeshow, 1989). La regresión logística es un procedimiento bien conocido que se puede utilizar para la clasificación. Esta es una variante de regresión múltiple en la que la respuesta es binaria en lugar de cuantitativa. En la versión más simple, las variables de características se consideran no aleatorias. La respuesta, que es la clase, es una variable aleatoria binaria que toma el valor 1 (para la clase de interés) con alguna probabilidad p , y el valor 0 con probabilidad $1 - p$.

Modelos de redes neuronales

Las redes de neuronas artificiales (RNA) son un sistema de unidades de procesamiento interconectadas que cooperan entre sí con el fin de generar una única señal. Una neurona artificial hereda los principios neurobiológicos que describen el comportamiento de las neuronas en el cerebro. Es un elemento simple que recibe entradas de fuentes externas sobre las que se aplica una función de activación f de las sumas ponderadas en función de pesos w ponderadas, cuyo valor sufre modificaciones durante el proceso de aprendizaje. Las redes neuronales artificiales presentan diferentes estructuras y arquitecturas, en el presente trabajo se implementaron las técnicas de aprendizaje automático Perceptron Multicapa y $K - Vecinos$ más cercanos.

Perceptron multicapa

La estructura básica de un perceptron multicapa está basada en neuronas artificiales que se agrupan en capas, considerando con las variables $X_1, X_2 \dots X_n$ como las variables de entradas a la neurona. Cada conexión presenta su propio peso específico, que puede ser tanto positivo como negativo. Una estructura de varios Perceptron o neuronas y sus conexiones es lo que se conoce como Modelo Perceptron Multicapa (MLP), de manera general el mismo está compuesto por varias capas de neuronas. La primera de ellas es la capa de entrada o externa, donde se recibe la información y la última capa es la de salida donde se obtiene la respuesta al problema. En medio de ambas capas se encuentran una o más capas intermedias llamadas capas ocultas.

K vecinos más cercanos

Es uno de los algoritmos de clasificación más básicos y esenciales en *Machine Learning*. Pertenece al dominio del aprendizaje supervisado y encuentra una aplicación intensa en el reconocimiento de patrones, la minería de datos y la detección de intrusos.

El clasificador KNN, por sus siglas en inglés, es también un algoritmo de aprendizaje no paramétrico y basado en instancias:

- No paramétrico significa que no hace suposiciones explícitas sobre la forma funcional de los datos, evitando modelar mal la distribución subyacente de los datos.
- El aprendizaje basado en la instancia significa que nuestro algoritmo no aprende explícitamente un modelo. En lugar de ello, opta por memorizar las instancias de formación que posteriormente se utilizan como “conocimiento” para la fase de predicción. Concretamente, esto significa que solo cuando se realiza una consulta a nuestra base de datos, es decir, cuando le pedimos que predique una etiqueta con una entrada, el algoritmo utilizará las instancias de formación para dar una respuesta.

Resultados

Los modelos del presente trabajo fueron implementados utilizando el lenguaje de programación R 4.0.0, dado la flexibilidad y potencial que el

mismo ofrece. Los modelos fueron divididos por *scripts* independientes para facilitar su comprensión y ejecución. A manera exploratoria de los datos de estudio lo primero que realizamos es un resumen estadístico de los datos observando la media desviación estándar entre otros y luego un análisis de correlación de los datos. Observándose que no existen variables con magnitudes con diferencias significativas.

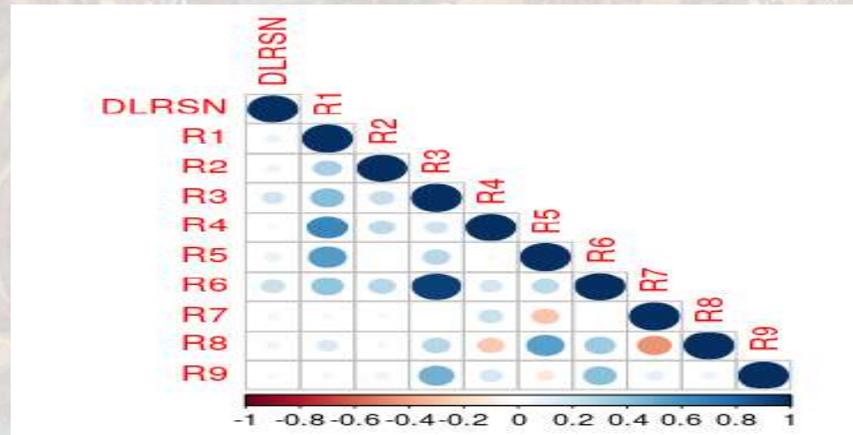
Tabla No 1
Resumen estadístico de las variables

R1	R2	R3	R4	R5
Min. :-0.49217	Min. :-0.008194	Min. :-0.15846	Min. :0.0183	Min. :0.176
1st Qu.: 0.02792	1st Qu.: 0.155650	1st Qu.: 0.06838	1st Qu.:0.1662	1st Qu.: 1.137
Median : 0.10872	Median :0.251884	Median : 0.10247	Median :0.2741	Median : 1.615
Mean : 0.11380	Mean : 0.268881	Mean : 0.11084	Mean :0.2973	Mean : 2.322
3rd Qu.: 0.18701	3rd Qu.: 0.362040	3rd Qu.: 0.14909	3rd Qu.:0.4009	3rd Qu.: 2.907
Max. : 0.53787	Max. : 0.597467	Max. : 0.33972	Max. :0.9161	Max. :13.507
R6	R7	R8	R9	
Min. :-0.11616	Min. :0.0107	Min. : 0.003	Min. : 0.382	
1st Qu.: 0.02693	1st Qu.:0.3410	1st Qu.: 1.232	1st Qu.: 1.818	
Median : 0.05681	Median :0.5626	Median : 2.017	Median : 2.941	
Mean : 0.06250	Mean :0.7292	Mean : 3.428	Mean : 3.668	
3rd Qu.: 0.09546	3rd Qu.:0.8591	3rd Qu.: 5.556	3rd Qu.: 4.241	
Max. : 0.22002	Max. :5.4149	Max. :15.900	Max. :29.740	

Fuente: Elaboración propia.

La correlación inicial mostrada en el presente grafico es baja de manera general de todas las variables con la variable dependiente y (DLRSN, éxito empresarial). Luego realizando un histograma de datos podemos observar como nuestros datos están bien balanceados a lo largo de su máximo y mínimo valor de manera general.

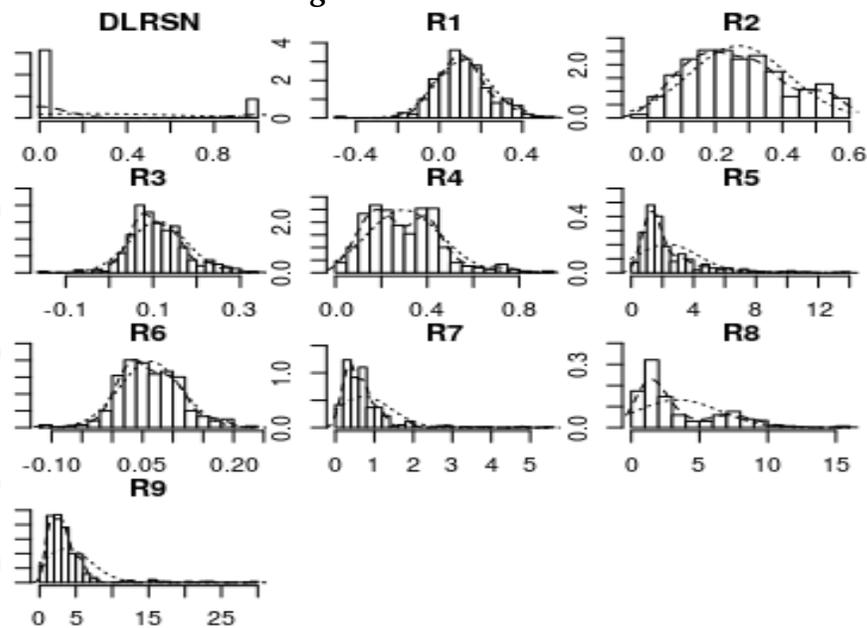
Gráfico No. 1
Correlación



Fuente: Elaboración propia

Para un correcto funcionamiento de los modelos desarrollados y para comprobar su precisión, la base de datos de estudio es dividida en un conjunto de datos de entrenamiento, correspondiente al 65% y el resto (35%) es destinado a verificar la precisión de predicción de los modelos. Dicha selección corresponde a obtener un mayor espectro de valores de validación del modelo sin desajustar el entrenamiento por falta de valores.

Grafico No. 2
Histograma de las variables



Fuente: Elaboración propia.

Regresión logística

El resultado arrojado por el modelo de regresión logística implementado no es bueno, como se observa en el resumen del modelo.

Tabla No. 2
Resumen del modelo

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-2.90063	0.84866	-3.418	0.000631 ***
R1	-2.45709	2.85921	-0.859	0.390142
R2	0.98518	1.35054	0.729	0.465715
R3	4.592	9.07749	0.506	0.612950
R4	0.56663	1.97812	0.286	0.774535
R5	0.06898	0.13695	0.504	0.614504
R6	13.61077	10.69931	1.272	0.203332
R7	0.41981	0.23692	1.772	0.076398 .
R8	0.05172	0.08532	0.606	0.544384
R9	-0.17928	0.1169	-1.534	0.125117

Fuente: Elaboración propia.

Como solamente el intercepto presenta un valor significativo, luego realizando una *stepwise regression* usando el criterio de AIC, donde el modelo final con el más bajo AIC fue obtenido manteniendo solamente las variables R6, R7, R9 y el intercepto AIC: 210.92 obteniendo una precisión en la clasificación de 40% solamente con los datos de prueba.

Tabla No. 3
Resumen del Modelo seleccionado por stepwise regresion usando AIC

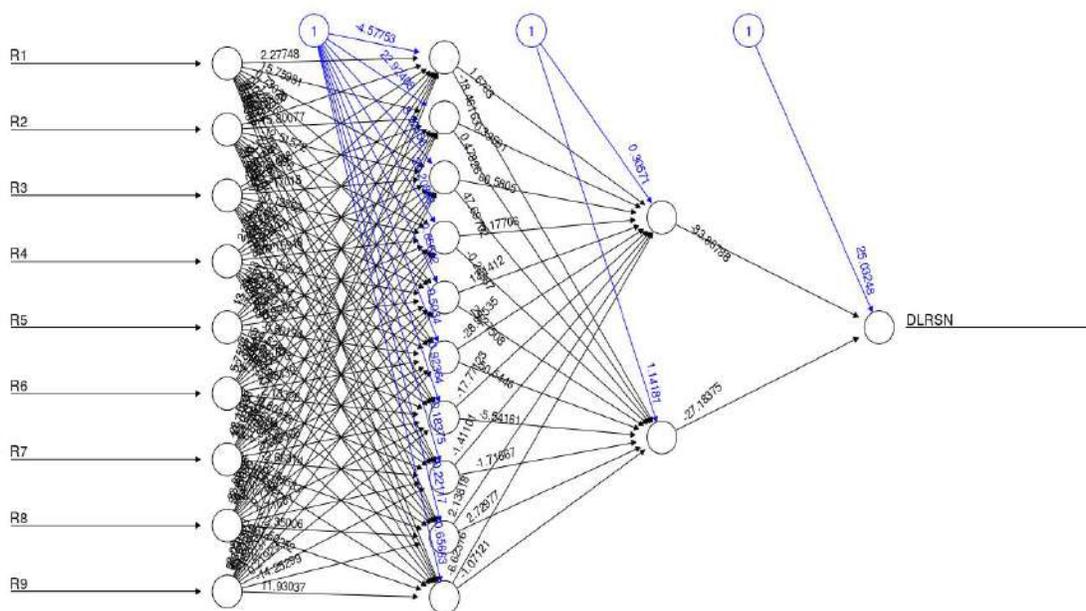
(Intercept)	-2.19427	0.40131	-5.468	4.56e-08 ***
R6	18.30306	4.48026	4.085	4.40e-05 ***
R9	-0.15776	0.09302	-1.696	0.0899 .
R7	0.34257	0.20768	1.649	0.0990 .

Fuente: Elaboración propia.

Perceptron multicapa

En el caso del perceptron multicapa se probaron varias arquitecturas, obteniendo los mejores resultados con una arquitectura de dos capas ocultas, la primera con 10 neuronas y la segunda con 2 neuronas, como se muestra en la siguiente imagen. Es necesario aclarar que, dado el volumen de datos, dígame empresas de muestra, años de estudios y cantidad de razones financieras, no se debe complejizar mucho el modelo ya que se puede realizar *overfitting*, una precisión muy alta en el entrenamiento, pero una mala validación posterior, puesto que el modelo haría lo que comúnmente se conoce como *memorizar los datos*.

Gráfico No. 3
Red Neuronal Perceptron Multicapa



Fuente: Elaboración propia.

Los resultados en el entrenamiento de la red perceptron son los siguientes:

Tabla No. 4
Matriz de confusión y resumen estadístico

Reference	Kappa : 0.8821
Prediction 0 1	Mcnemar's Test P-Value : 0.02334
0 154 7	Sensitivity : 1.0000
1 0 33	Specificity : 0.8250
Accuracy : 0.9639	Pos Pred Value : 0.9565
	Neg Pred Value : 1.0000
95% CI : (0.9271, 0.9854)	Prevalence : 0.7938
No Information Rate : 0.7938	Detection Rate : 0.7938
P-Value [Acc > NIR] : 5.99e-12	Detection Prevalence : 0.8299
	Balanced Accuracy : 0.9125
	'Positive' Class : 0

Observando una matriz de confusión con una precisión de un 96.39%, lo que es suficientemente bueno y en los datos de validación se obtiene:

Tabla No. 4
Matriz de confusión y resumen estadístico

Reference	Kappa : 0.2921
Prediction 0 1	Mcnemar's Test P-Value : 0.1530
0 72 16	Sensitivity : 0.9000
1 8 9	Specificity : 0.3600
Accuracy : 0.7714	Pos Pred Value : 0.8182
95% CI : (0.6793, 0.8477)	Neg Pred Value : 0.5294
No Information Rate : 0.7619	Prevalence : 0.7619
P-Value [Acc > NIR] : 0.4623	Detection Rate : 0.6857
	Detection Prevalence : 0.8381
	Balanced Accuracy : 0.6300
	'Positive' Class : 0

Se puede observar una clasificación con una predicción de 77.14%, lo que es bastante bueno, sobre todo si tenemos en cuenta que no tenemos una base de datos relativamente grande.

K-vecinos cercanos

Para el modelo de k-vecinos cercanos se comenzó por una red tomando un solo vecino y se fue incrementando hasta 10 vecinos, donde se obtuvo que los mejores resultados se obtenían con $k = 5$, tomando 5 vecinos cercanos, los resultados obtenidos para los datos de validación fueron los siguientes:

Tabla No.5
Matriz de confusión y resumen estadístico

Reference	Kappa : 0.9734
Prediction 0 1	Mcnemar's Test P-Value : 1
0 80 1	Sensitivity : 1.0000
1 0 24	Specificity : 0.9600
Accuracy : 0.9905	Pos Pred Value : 0.9877
95% CI : (0.9481, 0.9998)	Neg Pred Value : 1.0000
No Information Rate : 0.7619	Prevalence : 0.7619
P-Value [Acc > NIR] : 1.345e-11	Detection Rate : 0.7619
	Detection Prevalence : 0.7714
	Balanced Accuracy : 0.9800
	'Positive' Class : 0

La precisión del modelo es de un 99% de efectividad, se puede observar en la matriz de confusión que de 105 distintos datos el modelo solamente falla prediciendo uno. Como se pudo observar el de los tres modelos el modelo de regresión logística es el que peores resultados brinda, mientras los modelos de redes neuronales ofrecen mejores predicciones, sobre todo el modelo de k vecinos cercanos que presenta una precisión de 99%.

Conclusiones

Los resultados obtenidos muestran que el modelo de regresión logística es el que peores resultados ofrece para la predicción del éxito financiero de las empresas que conforman el IPC que cotizan en la BMV, esto puede estar condicionado por la imposibilidad de resolver directamente problemas no lineales, por encontrar valores atípicos o porque es un modelo muy simple para captar relaciones complejas entre las variables,

(como muestra el grafico de correlación), a diferencia de los modelos de *Machine Learning* que no están sometidos a condiciones paramétricas y convergen hacia la suposición de que todas las razones financieras tienen un aporte de una forma u otra en el éxito financiero.

De los dos modelos de *Machine Learning* presentados el Perceptron Multi-Capa (MLP) logro obtener una precisión de 96% en el *training* y un 77% en el *testing*, resultados satisfactorios teniendo en cuenta que se utilizó un diseño de arquitectura de red muy simple y el tamaño del conjunto de datos, por su parte el modelo de K- Vecinos más cercanos es el que mejores resultados obtiene en cuanto a su poder predictivo obteniendo un 99% de precisión en el *testing*.

A manera de resumen se concluye, que los modelos de *Machine Learning*, se presentan como una muy buena alternativa para los analistas financieros, los accionistas, los administradores de empresas y de manera general a los involucrados en este sector, constituyendo una potente herramienta que refuerce la certidumbre para una oportuna toma de decisiones financieras en busca de lograr el éxito financiero a nivel empresarial.

La presente investigación propone como nuevas líneas de desarrollo que den continuidad al estudio el incremento del tamaño de la colección de datos, agregando más empresas al estudio o incrementándose el rango del periodo estudiado a más de 10 años. El aumento de las razones financieras (variables independientes). Se pudieran asumir condiciones más severas sobre el éxito financiero a nivel empresarial, como tomar entre 3 y 5 años teniendo utilidades netas como factor de éxito o asumir una variación de la acción de mercado significativa. Así como complejizar la arquitectura del modelo de Perceptron Multi-Capa (MLP) esperando lograr así una mayor precisión en la predicción de los datos e implementar otras técnicas basadas en RNA para tener un mayor rango de comparación de resultados.

Referencias

Aguilera, D. A. (2018). *Un modelo global de predicción de quiebra con redes neuronales*.

Altman, E. (1968). *Financial ratios, discriminant analysis and the prediction of corporate bankruptcy*.

Altman, (Seudónimo) (1998). *Aplicación del Modelo Altman para empresas del mercado bursátil mexicano: un análisis comparativo de empresas exitosas y no eficientes en los 90's [sic]*, Investigación del Mercado de Valores, México, IMEF, [s.a].

Beaver, W. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*.

BMV. (2020). Bolsa mexicana de valores. Retrieved from <https://www.bmv.com.mx/>

CÁRDENAS, J.M (1997). *Metodología Paramétrica para la calificación y aprovisionamiento de la cartera hipotecaria*, Tesis de Licenciatura en Economía, México, ITAM, 108 pp., más bibliografía.

Casarejos, A. M. (2016). Predicción de quiebras empresariales mediante inteligencia artificial.

Coy, Peter. (5 de mayo de 2020). El Financiero. *Economía, Mercados y Negocios con Bloomberg*. ¿Cómo evitamos irnos todos a la quiebra? – El Financiero

Economics, T. (2020). *United states bankruptcies*. Retrieved from <https://tradingeconomics.com/united-states/bankruptcies>

Editores, S. H. T. (2020). *Covid-19, > ¿cómo salvarnos de la quiebra?* Retrieved from <https://www.infochannel.info/covid-19-como-salvarnos-de-la-quiebra>

Edward I. Altman, Robert G. Haldeman, P. Narayanan, ZETATM analysis A new model to identify bankruptcy risk of corporations, *Journal of Banking & Finance*, Volume 1, Issue 1, 1977, Pages 29-54, ISSN 0378-4266, [https://doi.org/10.1016/0378-4266\(77\)90017-6](https://doi.org/10.1016/0378-4266(77)90017-6)

Escobar, V. (2002). *Análisis de datos con redes neuronales aplicadas al diagnóstico de la solvencia empresarial*.

Evans, James and Lindsay, Williams (2008) *Administración y control de la calidad*. 7^{Ma} edición. Cengage Learning, México D.F., México.

García, I. V. (2017). *El modelo z de Altman como herramienta financiera para pronosticar o predecir el desempeño financiero de las empresas mexicanas cotizadas. Caso de las empresas manufactureras del sector alimenticio*.

INEGI. (2015). *Censos económicos 2014*. Resultados definitivos. Retrieved from <http://www.inegi.org.mx/est/contenidos/Proyectos/ce/ce2014/doc/presentacion/pprdce2014.pdf>

Fernado, Jason (2021) *Retained Earnings*. Obtenido de <https://www.investopedia.com/terms/r/retainedearnings.asp>

Fernado, Jason (2021) *Price-To-Book (P/B Ratio)*. Obtenido de <https://www.investopedia.com/terms/p/price-to-bookratio.asp>

Lozano, F.J., (2002) “Bases para la construcción de un modelo de predicción del éxito en las Pymes”, in Clemente Ruiz Durán (coord.), *Desarrollo empresarial en América Latina*, México, Nacional Financiera UNAM, pp. 195-238.

Morales, C. (2007). *Razones financieras que describen y clasifican a las empresas financieramente exitosas del sector comercial que cotizan en la Bolsa Mexicana de Valores*.

Morales, C. (2012). *Análisis comparativo del desempeño financiero de las empresas comerciales de la BMV a través de las técnicas adm, logit y rna*.

Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *SyJournal of Accounting Research*, 18 (1), 109-131. Retrieved from <http://www.jstor.org/stable/2490395>

Raluca Badea, I. H., & Matei, G. (2016). *The Z-Score Model for Predicting Periods of Financial Instability*. Z-Score Estimation for the Banks Listed on Bucharest Stock Exchange.

Rosillon, N., & Alejandra, M. (2009, 12). Análisis financiero: una herramienta-clave para una gestión financiera eficiente. *Revista Venezolana de Gerencia*, 14, 606-628. Retrieved from http://ve.scielo.org/scielo.php?script=sci_arttext&PID=S1315-99842009000400009&nrm=iso

Tam, Kar Yan and Kiang, Melody Y., (1992), Managerial Applications of Neural Networks: The Case of Bank Failure Predictions, *Management Science*, 38, issue 7, p. 926-947, <https://EconPapers.repec.org/RePEc:inm:ormnsc:v:38:y:1992:i:7:p:926-94>.

The Journal of Business, 74, 101-24. doi: 10.2139/ssrn.171436

Tamanara, (Seudónimo). *Conformación de un modelo de alerta temprana para evaluar el desempeño financiero de las empresas mexicanas*, Investigación, México, IMEF, [s.a.].

Taurell, O., & Augustsson, V. (2012). *Variables important for bankruptcy prediction: A logit binary approach*. (Bachelor Thesis)

Watkins, K (2003) “¿Previeron las empresas mexicanas la crisis financiera de 1995-1996? Un análisis de empresas”, *El trimestre económico*, Núm. 277, enero-marzo de 2003, México, Fondo de Cultura Económica, pp. 81-107.