

Clasificación de datos de cotización de la bolsa mexicana de valores usando aprendizaje automático

José Gonzalo Ramírez Rosas, Jorge de la Calleja,
Araceli Ortiz Carranco, Martín Neri-Suárez,
Salvador Antonio Arroyo Díaz

Universidad Politécnica de Puebla,
México

{jose.ramirez, jorge.delacalleja, araceli.ortiz,
martin.neri, salvador.arroyo}@uppuebla.edu.mx

Resumen. Las predicciones en el sector bursátil han sido un factor clave para que los inversionistas puedan tomar mejores decisiones y se minimice el riesgo que afrontan. Tradicionalmente, esta actividad se ha realizado manualmente o bien usando algunas herramientas de cómputo, sin embargo, en los últimos años la inteligencia artificial se ha empezado a aplicar en el área financiera para detectar patrones de comportamiento y así obtener mejores resultados en la predicción de datos. En el presente artículo se muestran los primeros resultados de un trabajo en desarrollo para la clasificación de los precios de cotización de algunas de las empresas que cotizan en el sector de productos de consumo frecuente de la Bolsa Mexicana de Valores, con el fin de apoyar en la toma de decisiones a los inversionistas. Para realizar los experimentos se obtuvieron los datos históricos (precios de cotización) de las empresas Bimbo, Chedraui, Femsá, Soriana y Walmex del periodo de 2010 al 2024. El software Weka se empleó para obtener los resultados de los algoritmos de aprendizaje automático utilizados tales como: el clasificador simple de Bayes, k-vecinos más cercanos, redes neuronales artificiales y máquinas de vectores de soporte, destacando árboles de decisión con una exactitud de clasificación con un promedio del 99%.

Keywords: Aprendizaje automático, clasificación, precios de cotización, finanzas.

Classification of Mexican Stock Exchange Quote Data Using Machine Learning

Abstract. Forecasting in the stock market has been a key factor in helping investors make better decisions and minimize the risk they face. Traditionally, this activity has been performed manually or using computing tools; however, in recent years, artificial intelligence has begun to be applied in the financial sector to detect behavioral patterns and thus obtain better results in data prediction. This article presents the initial results of an ongoing project to classify the stock prices of some of the companies listed in the consumer products sector of the Mexican Stock Exchange, with the aim of supporting investors in their decision-making.

To carry out the experiments, historical data (listed prices) were obtained from the companies Bimbo, Chedraui, Femsa, Soriana and Walmex from 2010 to 2024. The Weka software was used to obtain the results of the machine learning algorithms used such as: the simple Bayes classifier, k-nearest neighbors, artificial neural networks and support vector machines, highlighting decision trees with an average classification accuracy of 99%.

Keywords: Machine learning, classification, quote prices, finance.

1. Introducción

Dentro del sector financiero, el mercado bursátil juega un papel fundamental en la economía de los países. A través de éste, las empresas pueden acceder a financiamiento para llevar a cabo distintos tipos de inversión permitiéndoles expandirse, innovar y alcanzar sus metas financieras. Al mismo tiempo, el público inversionista, ya sean personas físicas o morales, busca incrementar su patrimonio mediante los rendimientos que ofrecen los mercados financieros. Estos rendimientos dependen de la variación en los precios de cotización de los activos financieros, los cuales reflejan el valor en moneda nacional de un activo en un momento determinado.

Es importante señalar que, el mercado bursátil se caracteriza por su dinamismo y volatilidad, lo que implica que los precios de los activos pueden fluctuar drásticamente en cortos periodos de tiempo. Esta volatilidad genera incertidumbre en los inversionistas, quienes deben tomar decisiones en un entorno en constante cambio. Además, se presenta el problema de la información asimétrica, donde no todos los inversionistas tienen acceso a la misma cantidad y calidad de información, lo que puede llevar a decisiones desinformadas Baca y Marcelino (2016) [1].

Así mismo, otro factor que influye en la volatilidad del mercado son los eventos externos como crisis económicas, cambios en políticas públicas y desastres naturales, los cuales pueden causar caídas abruptas en los precios de los activos financieros. Estos factores dificultan la predicción de los movimientos del mercado y aumentan el riesgo de inversión. Ante estos desafíos, es fundamental contar con herramientas que permitan analizar grandes volúmenes de datos y detectar patrones que ayuden a reducir la incertidumbre García (2015) [2].

Por otra parte, dentro del sector bursátil el dato de cotización se representa mediante valores como el precio de apertura, el precio más bajo, el precio más alto y el precio de cierre de un activo durante un periodo determinado. Estos datos son fundamentales para calcular las ganancias y pérdidas, así como para tomar decisiones estratégicas sobre la compra o venta de activos.

Dichas decisiones en el mercado de valores a menudo se reducen a una elección binaria: comprar o vender un activo en función de su comportamiento histórico y su tendencia futura. Para facilitar este proceso de decisión, los modelos de aprendizaje automático analizan las variables y generan predicciones basadas en patrones previamente identificados.

De lo anterior, el aprendizaje automático ha demostrado ser una tecnología clave para mejorar la toma de decisiones en el ámbito bursátil. Gracias a su capacidad de analizar grandes cantidades de datos históricos y detectar correlaciones, esta herramienta permite estimar tendencias del mercado con mayor exactitud. De esta manera, los inversionistas pueden minimizar riesgos y maximizar oportunidades de inversión Raschka y Mirjalili (2019) [3].

En este contexto el aprendizaje automático se puede entender como una rama de la inteligencia artificial (IA), que ha revolucionado el análisis financiero al proporcionar modelos predictivos y de clasificación más precisos y eficientes.

En el presente trabajo se muestran los primeros resultados de la evaluación del desempeño de algoritmos de aprendizaje automático para clasificar datos de valores de cotización de la BMV. Así, en una primera aproximación se podrá conocer cuál algoritmo es el que mejores resultados proporciona para que los inversionistas puedan usarlo como apoyo para la toma de decisiones para comprar o vender un activo financiero.

2. Trabajos relacionados

Para el desarrollo de la presente sección, la búsqueda de los trabajos se realizó en las bases de datos de *Scopus*, *Google Scholar* y *EBSCO*, utilizando como palabras clave en idioma inglés: *stock market and artificial intelligence*, *deep learning and finance*; seleccionando los artículos más cercanos con uso de algoritmos de aprendizaje automático en el sector bursátil.

De esta búsqueda se encontró que varios algoritmos de aprendizaje automático se han estado aplicando en la predicción y clasificación de datos financieros, destacando los algoritmos de: máquinas de vectores de soporte, redes neuronales artificiales, árboles de decisión, modelos de series de tiempo y modelos de memoria a corto plazo (LSTM). Enseguida se describen entonces aquellos trabajos más afines con el que se está desarrollando.

Para comenzar, Henrique, Sabreiro y Kimura en 2019 [4] expusieron que el algoritmo de máquina de soporte vectorial es una técnica efectiva para realizar predicciones a corto plazo, especialmente cuando se utilizan ventanas de tiempo reducidas. Su capacidad para capturar patrones en datos recientes la hace una opción confiable en escenarios de alta frecuencia, no obstante, su precisión tiende a disminuir en pronósticos a largo plazo debido a la creciente volatilidad del mercado, por lo tanto, factores como cambios inesperados en las tendencias y la acumulación de errores afectan su desempeño, lo que limita su aplicación en horizontes temporales más amplios.

Así también, Strader, Rozycki, Root y Huang en 2020 [5] sugieren que el aprendizaje automático posee un potencial significativo en la predicción del mercado, sin embargo, su eficacia depende de diversos factores, como la calidad de los datos y la robustez de los modelos empleados; por lo anterior para mejorar la precisión de estas predicciones, es fundamental realizar más estudios sobre la integración de múltiples fuentes de datos y la optimización de los algoritmos, así como modificar los hiperparámetros, esto

permitirá desarrollar modelos más sofisticados y adaptativos, capaces de captar mejor la dinámica del mercado.

De la misma forma, los modelos de aprendizaje automático, como las redes neuronales y los árboles de decisión, han demostrado un desempeño sólido en la predicción del mercado, su capacidad para identificar patrones complejos y adaptarse a grandes volúmenes de datos los convierte en herramientas valiosas para el análisis financiero; además, la precisión de las predicciones mejora significativamente cuando se combinan varios métodos de inteligencia artificial. Tal como la integración de enfoques complementarios que permite reducir errores y optimizar el procesamiento de la información, así como obtener resultados más confiables en diferentes condiciones del mercado Sahrab, Kang y Jin, 2021[6].

Coy, Granados y García en 2021[7] expusieron que los modelos de series temporales, como ARIMA y GARCH, continúan siendo herramientas fundamentales en la predicción financiera, su capacidad para modelar la dependencia temporal y la volatilidad los hace ampliamente utilizados en el análisis de tendencias y riesgos de los mercados, no obstante, la creciente complejidad de los datos financieros ha evidenciado la necesidad de modelos más avanzados. En este contexto, las redes neuronales recurrentes han surgido como una alternativa prometedora, ya que pueden capturar patrones no lineales y adaptarse mejor a las dinámicas cambiantes del mercado.

Por su parte, Cuevas, Alvares, Azcona y Rodríguez en 2019[8] en su estudio desarrollaron un modelo para pronosticar la proyección de los ingresos de una empresa a través del algoritmo de máquinas de soporte vectorial, si bien el estudio no fue desarrollado para el sector bursátil, fue empleado en el área financiera, teniendo como resultado que este algoritmo es adecuado para la clasificación y predicción de series de tiempo en el ámbito financiero.

Chhajer, Shah y Kshirsagar en el 2022 [9] demostraron que los *Long short-term memory* (LSTM) mostraron un rendimiento superior en la predicción a largo plazo gracias a su capacidad para manejar secuencias temporales de manera efectiva, su arquitectura permite retener información relevante a lo largo del tiempo, lo que mejora la precisión en la identificación de tendencias y patrones complejos en los datos de cotización. Por otro lado, los modelos de máquina de soporte vectorial y redes neuronales, también obtuvieron buenos resultados, aunque presentaron limitaciones en la captura de relaciones temporales más complejas. Si bien pueden ser útiles en ciertos contextos, su desempeño es menos eficiente en comparación con LSTM cuando se trata de datos secuenciales de largo plazo.

Cabe señalar que, García, Garzón y López en 2023 [10] concluyeron que las técnicas de *soft computing*, como las redes neuronales, la lógica difusa y los algoritmos genéticos, ofrecen ventajas significativas sobre los métodos tradicionales de predicción de mercados, su capacidad para procesar grandes volúmenes de datos y reconocer patrones no lineales les permite abordar la naturaleza dinámica y cambiante de los mercados financieros. Además, estas técnicas destacan por su mayor flexibilidad y adaptabilidad, lo que las hace especialmente eficaces para modelar incertidumbre y variabilidad, a diferencia de los enfoques convencionales, pueden ajustarse de manera más precisa a condiciones de mercado complejas, mejorando así la toma de decisiones en entornos financieros.

De la misma manera, Lin y Lobo en 2024 [11] destacan el crecimiento en el uso de técnicas de inteligencia artificial, como redes neuronales y algoritmos de aprendizaje

profundo, en la predicción del mercado, estas herramientas han demostrado ser altamente efectivas para identificar patrones complejos y mejorar la capacidad de anticipación en entornos financieros dinámicos, además la combinación de inteligencia artificial con análisis técnico y fundamental ha permitido mejorar significativamente la precisión en las predicciones, esto al integrar múltiples fuentes de información con enfoques que ofrecen una visión más completa del comportamiento del mercado, optimizando así la toma de decisiones y reduciendo la incertidumbre.

Igualmente, se destaca el uso de algoritmos como las redes neuronales y Long-Short-Term Memory (LSTM), para la predicción de los índices bursátiles en especial el IPC de México y el Standard & Poor's (S&P), los cuales fueron eficaces para la contribución de la gestión económica y optimización de recursos en la toma de decisión, arrojando como resultados positivos para la predicción al algoritmo LSTM presentando errores por debajo del 4% Andrade et al 2024 [12]

También, otro estudio de Ricchiuti y Sperli en 2025 [13] aplicaron los LSTM utilizado en el mercado de criptomonedas que ha demostrado la eficiencia en el retorno de los rendimientos, pues la predicción con respecto a los precios de cotización de estos activos demostró un retorno del 39%

Sin embargo, existen estudios que están utilizando la inteligencia artificial basados en datos de procesamiento de lenguaje natural para poder clasificar las acciones del mercado bursátil y con ello poder hacer una predicción con respecto a las tendencias que presentan los activos Arifonang, Wiryono y Faturohman 2025 [14]

Así mismo, la inteligencia artificial aplicada en las finanzas ha tomado gran relevancia, pues se ha tenido evidencia científica de que las personas están utilizando los algoritmos de aprendizaje automático para gestionar sus carteras de inversión, esto con el fin de maximizar sus rendimientos y minimizar los riesgos que presentan sus inversiones Banerjee, 2025 [15]

En un estudio de Ning, Zhaang y Wang en 2025 [16], experimentaron con los algoritmos de aprendizaje automático para minimizar los riesgos en las inversiones, los hallazgos fueron que a través del uso de los datos de las empresas que cotizan en la bolsa de Shanghai y Shenzhen por el periodo de 2007 al 2020 estabilizó el riesgo de la caída en las acciones y se pudo mejorar el desempeño de las inversiones en el mercado de capitales de aquella bolsa bursátil.

De lo presentado anteriormente, se puede notar que los algoritmos de árboles de decisión y redes neuronales destacaron como los de mejor desempeño en la clasificación de datos de cotización, como lo señalan Sahrab, Kang y Jin en su estudio de 2021, sin embargo, como se ha visualizado el algoritmo *Long-Short-Term Memory* ha demostrado resultados favorables en la parte bursátil como lo señalan los estudios de Andrade et al en 2024 y de Chhajer, Shah y Kshirsagar en 2022, pero, en su esencia éste algoritmo no presenta una funcionalidad para los datos de serie de tiempo como lo exponen en su mismo trabajo.

3. Metodología y métodos

La presente investigación tiene un corte de enfoque cuantitativo dado que se está midiendo la exactitud de la clasificación de los datos de cotización de las empresas seleccionadas. Desde el punto de vista de la finalidad, se trata de una investigación

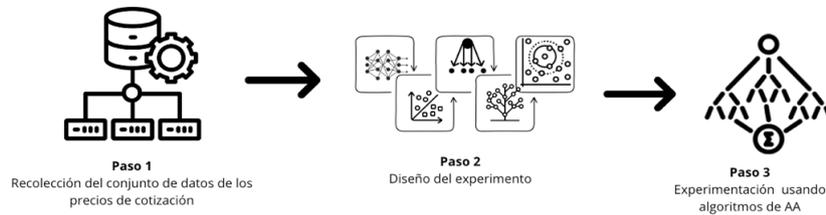


Fig. 1. Etapas principales para realizar la clasificación de los datos de cotización.

aplicada porque se podrá conocer el algoritmo que mejor desempeño de clasificación tendrá en los datos de cotización.

3.1. Metodología

En la figura 1 se muestra un diagrama de las principales etapas para el desarrollo del presente trabajo, que son: recolección de datos, el diseño del experimento y la experimentación usando los algoritmos de aprendizaje automático del software WEKA (*Waikato Environment for Knowledge Analysis*); a continuación, se describe cada una de éstas.

Etapa 1. En este paso, se diseñó un sistema de descarga de datos en lenguaje Python utilizando la librería *yfinance*, lo que permitió acceder a información relevante de estas compañías. Dado que las bases de datos no son de acceso público, el acceso a los datos se realiza a través de la API de Yahoo Finanzas, la cual recopila información de las bolsas de valores de distintos países, sin embargo, es importante destacar la responsabilidad en el manejo de estos datos, asegurando su correcta interpretación y uso.

Así también, se llevó a cabo la selección de las empresas BIMBO, CHEDRAUI, FEMSA, SORIANA y WALMEX que pertenecen al sector de bienes de consumo frecuente en México, estas entidades representan una parte significativa del mercado, ya que con base en el Financiero [17] aportaron una inversión en el año 2024 en promedio de 94 mil millones de pesos mexicanos, y son consideradas como centros de consumo listados en el mercado de capitales local con base en el método que se describe en la figura 1.

Es preciso señalar que, la información al ser pública las empresas son auditadas por el máximo organismo financiero en México que es la Secretaría de Hacienda y Crédito Público (SHCP), en este sentido la información recopilada se entiende verídica. Este sistema facilita la recopilación de datos históricos de cotización y otros indicadores financieros esenciales para su clasificación y estudio, tales como precio de cotización de apertura, bajo, alto y de cierre, también se determina el volumen de operaciones, así como la rentabilidad y volatilidad, se tiene un atributo de decisión binaria de sí o no de invertir; por último, la recolección de datos en promedio fue de 3700 por cada una de las cinco empresas analizadas.

Tabla 1. Resultados de clasificación correcta de los algoritmos.

	BIMBO (%)	CHEBRAUI (%)	FEMSA (%)	SORIANA (%)	WALMEX (%)
Árboles de decisión	99.9	99.9	99.9	100	100
Clasificador Simple de Bayes	94.5	95.7	92.7	91.2	96.5
K-vecinos más cercanos	92.8	95.7	91.1	90.4	95.9
MVS	98.3	97.9	97.7	91.4	98.8
Redes Neuronales	97.7	98.4	97.9	96.9	98.3

Fuente: Elaboración propia con base en los resultados por *weka*. En esta tabla se puede observar los resultados en porcentaje de las clasificaciones correctas de los algoritmos.

Etapa 2. En este paso se diseñó el experimento en el que cada algoritmo seleccionado se ejecutó cinco veces de forma independiente, modificando el *random seed* en cada una de éstas, el rendimiento final se determinó promediando los resultados de estas cinco ejecuciones; lo anterior utilizando un *cross validation fold* de 10, por lo que se realizaron 50 experimentaciones de cada algoritmo.

Etapa 3. Para este paso, se experimentó con los algoritmos seleccionados y los datos descargados en el paso 1 los cuales fueron procesados y analizados utilizando la herramienta WEKA, una plataforma especializada en minería de datos y aprendizaje automático. WEKA permite utilizar distintos algoritmos de clasificación y evaluación de modelos para identificar relaciones dentro de los datos financieros.

En este análisis, se emplearon los hiper parámetros por defecto de cada algoritmo, para obtener una primera aproximación a la clasificación de los datos de forma correcta e incorrecta, lo que permitió evaluar el comportamiento de distintos algoritmos sin la necesidad de realizar ajustes manuales previos; por último, este paso sirvió como punto de partida para identificar cuáles modelos podrían ser más efectivos en la predicción y segmentación de los datos de las empresas seleccionadas a través de los algoritmos de árboles de decisión, clasificador simple de Bayes, k-vecinos más cercanos, máquinas de soporte vectorial y red neuronal.

4. Resultados experimentales

Para realizar los experimentos se usaron datos de cinco empresas de las más representativas que cotizan en la Bolsa de Valores en México del mercado de capitales. La recolección de datos se hizo considerando el periodo del año 2010 al 2024, tomando en cuenta los atributos de los precios de cotización que son: precio de apertura, precio máximo, precio alto, precio bajo, precio de cierre, precio de cierre ajustado, rendimiento, volatilidad; y teniendo como valor de decisión para la clasificación si se invierte o no.

Tabla 2. Resultados de la mejor matriz de confusión para el algoritmo de árboles de decisiones.

Conjunto de datos	a	b
Walmex	5253	0
	0	1885

Fuente: Elaboración propia con base en los resultados por *weka*. En esta tabla se puede observar la clasificación del conjunto de datos de Walmex.

Tabla 3. Resultados de la mejor matriz de confusión para el algoritmo clasificador simple de Bayes.

Conjunto de datos	a	b
Walmex	1790	63
	66	1819

Fuente: Elaboración propia con base en los resultados por *weka*. En esta tabla se puede observar la clasificación del conjunto de datos de Walmex.

Tabla 4. Resultados de la mejor matriz de confusión para el algoritmo k vecinos más cercanos.

Conjunto de datos	a	b
Chedraui	1437	64
	62	1362

Fuente: Elaboración propia con base en los resultados por *weka*. En esta tabla se puede observar la clasificación del conjunto de datos de Chedraui.

Tabla 5. Resultados de la mejor matriz de confusión para el algoritmo red neuronal simple.

Conjunto de datos	a	b
Chedraui	1861	16
	41	1739

Fuente: Elaboración propia con base en los resultados por *weka*. En esta tabla se puede observar la clasificación del conjunto de datos de Chedraui.

Tabla 6. Resultados de la mejor matriz de confusión para el algoritmo de maquinas de soporte vectorial.

Conjunto de datos	a	b
Walmex	1840	13
	28	1857

Fuente: Elaboración propia con base en los resultados por *weka*. En esta tabla se puede observar la clasificación del conjunto de datos de Walmex.

La experimentación fue realizada usando el software *Weka* como ya se comentó en párrafos anteriores, utilizando las implementaciones de los algoritmos de árboles de decisión, clasificador simple de Bayes, máquinas de vectores de soporte, redes neuronales artificiales y k-vecinos más cercanos, y usando los valores de los hiper parámetros que están por defecto. Así, algunos de los valores usados fueron: para AD se tomó como factor de confianza de 0.25, para el CSB se consideró un tamaño de lote de 100, para k-nn se usaron 3 vecinos y la distancia Euclidiana, para MVS se utilizó un

Tabla 7. Resultados de las métricas precisión y media F.

Nombre del algoritmo	Precisión	Medida F
Árboles de decisión	1	1
Clasificador simple de Bayes	0.94332	0.9416
K-vecinos más cercanos	0.93248	0.93244
Máquinas de soporte vectorial	0.9702	0.96856
Red neuronal simple	0.97896	0.97868

Fuente: Elaboración propia con base en los resultados por *weka*. En esta tabla se puede observar el promedio de las métricas de precisión y medida F por cada algoritmo.

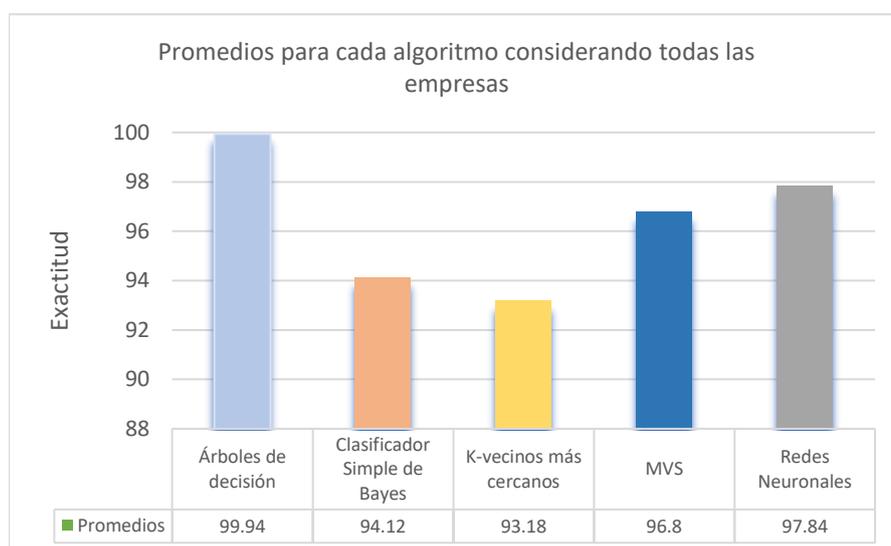


Fig. 2. La presente figura expone los promedios por empresa respecto al algoritmo con mejor desempeño que fue el de árbol de decisión.

kernel de función lineal, mientras que para las RNA se tuvo una tasa de aprendizaje de 0.3 y 500 épocas para el entrenamiento. Nuevamente es importante mencionar que al tratarse de los primeros experimentos, se ha decidido no modificar estos valores que están previamente establecidos.

En la Tabla 1 se muestra el promedio de 5 ejecuciones de los algoritmos, usando *10-fold cross-validation*. Se puede observar que el algoritmo de árboles de decisión obtuvo los mejores resultados para todas las empresas, logrando inclusive una exactitud del 100% para las empresas de Soriana y Walmex, y del 99.9% para Bimbo, Chedraui y Femsa. Los segundos mejores resultados fueron obtenidos con los algoritmos de máquinas de vectores de soporte y redes neuronales, con valores del 97% y 98% en algunos casos. Así también, se puede observar que el algoritmo que obtuvo los resultados más bajos fue k-vecinos más cercanos, teniendo un 90.4% para la empresa de Soriana.

En las tablas de la 2 a la 6 se muestran las mejores matrices de confusión de cada conjunto de datos, de los diferentes algoritmos implementados en *Weka*, siendo para los cinco casos la nomenclatura marcada de la siguiente manera: a una clasificación tipo no, y b una clasificación tipo sí.

En lo que respecta a las métricas de precisión y medida F, se tomaron en cuenta los promedios de los cinco conjuntos de datos de cada algoritmo que se aplicó en el software *weka*, obteniendo los resultados que se describen en la tabla 7.

Por último, como se puede observar en la figura 2, el algoritmo de árboles de decisión fue el que tuvo mejor desempeño con respecto a la clasificación de los datos de las cinco empresas; en el caso de las empresas Bimbo, Chedraui y Femsa, aunque no llegaron a tener una clasificación del 100% como los datos Soriana y Walmex, fue el algoritmo mejor evaluado con respecto a los demás.

5. Conclusiones

Los resultados obtenidos permiten concluir que el algoritmo de árboles de decisión demostró el mejor desempeño en la clasificación de los datos. Su efectividad radica en su capacidad inherente para modelar decisiones binarias de manera eficiente, lo que lo hace particularmente adecuado para el análisis bursátil. Esto concuerda con lo reportado en la literatura, específicamente en los trabajos de Sahrab, Kang y Jin 2021 [6].

Cabe señalar que, el conjunto de datos utilizado para cada empresa contiene 3,700 registros por lo que, se puede inferir que la cantidad de datos no limitó significativamente la capacidad de clasificación. La literatura sugiere que estos algoritmos pueden mejorar su rendimiento a medida que el volumen de datos aumenta, lo que abre la posibilidad de mejorar mediante el uso de conjuntos de datos más extensos.

Finalmente, el alto rendimiento del algoritmo de árboles de decisión, particularmente cuando se aproxima al 100%, podría ser indicativo de sobreajuste a los datos de entrenamiento. Por lo tanto, se recomienda realizar un ajuste de hiperparámetros, como la profundidad máxima del árbol para evaluar su desempeño.

Como trabajo a futuro, en primer lugar se considera ampliar el número de registros de otras empresas pertenecientes al sector V -bienes de consumo frecuente en México, en segundo lugar obtener los datos de otros sectores tal como el sector III- Industrial y el sector VIII que corresponde a Tecnología de la Información, para realizar los experimentos correspondientes como lo expuesto en el presente artículo; por último, se modificarán algunos valores de los hiperparámetros de los algoritmos con el objetivo de mejorar los resultados obtenidos.

Referencias

1. Baca, G., Marcelino, M.: Ingeniería Financiera. México: Editorial Patria (2016)
2. García, V. M.: Análisis Financiero: Un enfoque integral. México: Editorial Patria (2015)
3. Raschka, S., Mirjalili, V.: Python Machine Learning. México: Marcombo (2019)
4. Henrique, B., Sobreiro, V., Kimura, H.: Uso de regresión vectorial de soporte (SVR) para la predicción de precios de acciones. *Expert Systems with Applications*, pp. 226–251 (2019)

5. Strader, T., Rozycki, J., Root, T., Huang, Y.: Revisión de estudios sobre la predicción del mercado de valores mediante aprendizaje automático. *Journal of International Technology and Information Management Journal of Internatio*, pp. 63–83 (2020) doi: 10.58729/1941-6679.1435.
6. Sahrab, M., Kang, Y., Jin, L.: Eficiencia de la IA en la predicción del mercado de valores mediante el aprendizaje automático. *Electric Power Systems Research*, pp. 1–11 (2021)
7. Coy, G., Granados, O., Garcia, O.: Predicción de la serie temporal del indicador bancario de referencia (ibr) con redes neuronales. *Revista Mutis*, pp. 65–76 (2021) doi: 10.21789/22561498.1748.
8. Cuevas, M., Alvares, S., Azcona, M.: Capacidad predictiva de las Máquinas de Soporte Vectorial. Una aplicación en la planeación financiera. *Revista Cubana de Ciencias Informáticas*, pp. 59–75 (2019)
9. Chhajer, P., Shah, M., Kshirsagar, A.: The applications of Artificial Neural Networks, Support Vector Machines, and Long–Short Term memory for stock market prediction. *Decision Analytics Journal*, pp. 1–12 (2022) doi: 10.1016/j.dajour.2021.100015.
10. García, M., Jalal, A., Garzón, L.: Métodos para predecir índices bursátiles. *Ecos de Economía*, pp. 51–82 (2023)
11. Lin, C., Lobo, J.: Stock Market Prediction Using Artificial Intelligence: A Systematic Review of Systematic Reviews. *Social Sciences & Humanities Open*, pp. 1–11 (2024) doi: 10.1016/j.ssaho.2024.100864.
12. Andrade-Gorjoux, L.E., González-Contreras, J.F., Montiel-Pérez, J.Y.: Comparación entre Codificación Predictiva Lineal (LPC) y Red Neuronal Artificial Long Short-Term Memory (LSTM) para la predicción financiera del Índice de Precios y Cotizaciones (S&P/BMV IPC). *POLIBITS*, 65(1), pp. 19–26 (2024)
13. Ricchiuti, F., Sperlí, G.: An Advisor Neural Network Framework Using LSTM-Based Informative Stock Analysis, *Expert Systems with Applications* (2024) doi: 10.1016/j.eswa.2024.125299.
14. Aritonang, P.K., Wiryono, S.K., Faturohman, T.: Hidden-Layer Configurations in Reinforcement Learning Models for Stock Portfolio Optimization, *Intelligent Systems with Applications* (2024) doi: 10.1016/j.iswa.2024.200467.
15. Banerjee, S.: Portfolio Management With the Help of AI: What Drives Retail Indian Investors to Robo-Advisor Electronic, *Journal of Information Systems in Developing Countries*, 91(1) (2025) doi: 10.1002/isd2.12346.
16. Ning, F., Jin, J., Zhang, L.: Risk Analysis of China's Financial Market Collapse Based on Cloud Computing and Machine Learning Algorithms, *Expert Systems*, 42(1) (2025) doi: 10.1111/exsy.13426.
17. El Financiero (2024) <https://www.elfinanciero.com.mx/empresas/2024/03/26/empresas-como-bimbo-walmart-y-femsa-invertiran-184-mil-877-mdp/>