

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)

Luis Enrique Andrade-Gorjoux, Jordi Fabián González-Contreras,
Jesús Yaljá Montiel-Pérez and Jesús Alberto Martínez-Castro

Resumen—En esta investigación se evalúa la efectividad de los métodos de predicción, Codificación Predictiva Lineal (LPC) y la Red Neuronal Artificial Long Short-Term Memory (LSTM), con miras a optimizar la gestión financiera y la toma de decisiones en el ámbito financiero, aplicadas a la predicción del comportamiento de una serie de tiempo caótica utilizando datos históricos del Índice de Precios y Cotizaciones (S&P/BMV IPC), indicador clave en México que refleja el rendimiento del mercado bursátil en nuestro país. Los resultados obtenidos revelan las redes LSTM presentan un error por debajo del 4% aunque un mayor tiempo para la obtención de resultados, caso contrario obtenido con la técnica LPC, lo que sugiere que pueden resultar útiles en diferentes contextos y para diversos objetivos financieros tras la comparación entre estos métodos que incluyen la exactitud de las predicciones, el margen de error asociado y la capacidad de adaptación a las fluctuaciones del mercado. Este trabajo aporta una comparativa entre estos dos métodos para la predicción al campo financiero a los tomadores de decisiones, inversionistas y al mismo gobierno. Además, los hallazgos pueden contribuir a una gestión económica eficaz y sostenible en un mundo que se encuentra en constante transformación digital y enfocado en la optimización de recursos.

Palabras clave—Economía, predicción financiera, S&P/BMV IPC, computación, codificación predictiva lineal (LPC), red neuronal artificial (RNA), long short-term memory (LSTM).

Comparison between Linear Predictive Coding (LPC) and Long Short-Term Memory (LSTM) Artificial Neural Network for Financial Prediction of the Price and Quotation Index (S&P/BMV IPC)

Abstract—In this research, the effectiveness of prediction methods, Linear Predictive Coding (LPC), and the Long Short-Term Memory Artificial Neural Network (LSTM) are evaluated, aiming to optimize financial management and decision-making in the financial domain, applied to predicting the behavior of a chaotic time series using historical data from the Índice de Precios y Cotizaciones (S&P/BMV IPC), a key indicator in Mexico reflecting the performance of the stock market in our country. The results obtained reveal that LSTM networks have an error rate

below 4%, although they require more time to obtain results compared to LPC technique, suggesting their potential utility in different contexts and for various financial objectives, following the comparison between these methods, which include prediction accuracy, associated error margin, and ability to adapt to market fluctuations. This work provides a comparative analysis between these two prediction methods in the financial field for decision-makers, investors, and the government. Additionally, the findings may contribute to effective and sustainable economic management in a world undergoing constant digital transformation and focused on resource optimization.

Index Terms—Economy, financial prediction, S&P/BMV IPC, computing, linear predictive coding (LPC), artificial neural network, (ANN), long short-term memory (LSTM).

I. INTRODUCCIÓN

El análisis financiero y las técnicas de predicción son fundamentales para la toma de decisiones económicas e impulsadas por el uso de las nuevas tecnologías. Esto se evidencia en la predicción del S&P/BMV IPC de México, uno de los principales indicadores económicos que permite visualizar la salud financiera del país tras su composición de las 35 empresas con mayor liquidez. Este Índice forma parte del análisis técnico de movimientos bursátiles, permitiendo la observación de la evolución temporal del comportamiento del mercado, considerando todos los factores asociados a esos activos de manera implícita [1].

La transformación digital y la optimización de recursos, que son aspectos clave a considerar en función de la agenda 2030 acordada entre los miembros de la Organización de las Naciones Unidas [2], entre ellos México, ofrece una guía y fundamento de este trabajo.

En este sentido, en el presente trabajo se sigue el Objetivo de Desarrollo Sostenible (ODS) 9 (Industria, Innovación e Infraestructura) tras la innovación de este tipo de tecnologías en el sector económico plateado y el ODS 12 (Producción y Consumo Responsables) al brindar un fundamento en el uso responsable de recursos en los diversos sectores económicos del país tras la visión financiera que se pudiera plantear y el desarrollo sostenible que se pueda alcanzar. Por lo tanto, este trabajo no solo contribuye al campo financiero, sino que también tiene implicaciones para el logro de estos objetivos.

The authors are with the Instituto Politécnico Nacional (IPN), Centro de Investigación en Computación (CIC), México {{landradeg2022, jgonzalezc2023, jyalja, macj}@cic.ipn.mx}.

Manuscript received on 16/04/2023, accepted for publication on 20/05/2023.

Es así como este trabajo compara los enfoques predictivos en la predicción financiera del S&P/BMV IPC de México, considerando la precisión, el margen de error y la adaptabilidad a las fluctuaciones del mercado.

Los métodos LPC y LSTM se seleccionaron debido a su eficacia comprobada en la predicción de series temporales en diversas disciplinas, desde ingeniería hasta economía. El LPC es una técnica clásica demostrada en varias aplicaciones de predicción [3] y se compara, en términos de exactitud de los datos, el margen de error y la adaptabilidad a las fluctuaciones del mercado, con el método LSTM, un enfoque más reciente impulsado por avances en inteligencia artificial, reconocido por su capacidad para capturar relaciones a largo plazo en los datos [4].

Esta investigación proporciona un soporte en el proceso de tomas de decisiones a inversores y autoridades gubernamentales al evaluar la salud financiera tras el uso de alguna de las dos técnicas de predicción.

Además, sus hallazgos pueden impulsar la gestión eficiente y sostenible en un entorno económico desafiante y dinámico, destacando la importancia de la elección adecuada de técnicas de predicción.

II. DEFINICIÓN DEL PROBLEMA Y REVISIÓN DE LITERATURA

A. Problema

Los Índices bursátiles, como el S&P/BMV IPC, son indicadores cruciales para evaluar la salud financiera de una región; sin embargo, su comportamiento es notoriamente complejo y está caracterizado por una no linealidad, la cual es consecuencia de un conjunto de factores que influyen en su dinámica [5]. Esta complejidad plantea desafíos significativos para la predicción precisa.

Con la necesidad de agilizar y fundamentar la toma de decisiones financieras, recurrimos al uso de herramientas de predicción para anticipar el futuro comportamiento del mercado financiero mexicano. En este contexto, se ha optado por LPC y LSTM. Estos métodos han demostrado su eficacia en el procesamiento de señales y series temporales, así como en el análisis de datos con fines predictivos.

El objetivo central de esta investigación es evaluar la eficacia de dos enfoques diferentes en la predicción de uno de los principales Índices bursátiles de América Latina, el S&P/BMV IPC, con el propósito de anticipar las tendencias del mercado y proporcionar información de alto valor para la toma de decisiones.

En este contexto, se justifica la utilización de los métodos de predicción, con el propósito de mitigar el error en los valores calculados. Este esfuerzo es crucial, ya que el error en las predicciones puede dar lugar a decisiones financieras desinformadas o afectar la capacidad de atraer inversiones y restringir el desarrollo económico.

B. Trabajos relacionados

El análisis de datos financieros desempeña un papel fundamental al ofrecer una comprensión más profunda del comportamiento financiero, proporcionando información valiosa sobre el rendimiento de empresas e industrias, así como sobre la salud económica en su conjunto.

Según lo señalado en [5], la posibilidad de predecir y clasificar datos financieros permite la identificación de tendencias clave, lo que contribuye al proceso de toma de decisiones y facilita la formulación de estrategias efectivas para el desarrollo económico.

En [6], se resalta la influencia del sistema económico de una ciudad en la productividad, la adopción y el desarrollo de nuevas industrias, lo cual tiene un impacto directo en los indicadores financieros que representan a estas áreas geográficas.

Al mismo tiempo, un sistema financiero que llegara a ser inteligente, se convierte en un instrumento para medir la eficiencia y financiar avances tecnológicos.

En concordancia con esto, se enfatiza en [7, 8] una relevancia de la predicción financiera, basada en el modelado financiero y el análisis de datos, escenarios y riesgos. Este enfoque puede desempeñar un papel fundamental en garantizar la sostenibilidad financiera de proyectos e iniciativas, como infraestructura y servicios. Así mismo, se analiza el beneficio de asegurar que estas inversiones sean viables desde el punto de vista financiero y generen un retorno positivo es de gran importancia.

Los algoritmos estadísticos de modelado y predicción de mercados, como el LPC, se basan en las suposiciones de estacionariedad de series temporales y linealidad entre variables con distribución normal como se menciona en el estudio de referencia [9].

Algunos de los algoritmos que se han implementado con este propósito incluyen Monte Carlo [10], el Modelo Autorregresivo Integrado de Media Móvil (ARIMA) [11], el Análisis de Componentes Principales (PCA) [12], árboles de decisión [13], regresión de soporte vectorial [14] y redes neuronales artificiales [15, 16].

El método LPC, menciona [17], empleado en el área de finanza con enfoque predictivo se presenta como punto de referencia frente a otros algoritmos de predicción basados en inteligencia artificial, como las redes neuronales, concluyendo que tuvo un desempeño menos favorable.

Además, en [18], se analiza su aplicación en el ámbito financiero, específicamente para la estimación de la volatilidad de las acciones, y se evidencian resultados más favorables en comparación con el modelo autorregresivo generalizado condicional heterocedástico (GARCH, por sus siglas en inglés).

Por otro lado, las redes neuronales LSTM representan un modelo avanzado de redes neuronales recurrentes (RNN) debido a que es un algoritmo de aprendizaje profundo pues es capaz de gestionar secuencias extensas de unidades de datos gracias a su capacidad de recordar información pasada, la cual puede ser utilizada para procesar futuras entradas [19], son efectivas en tareas de series de tiempo como lo es el caso de la predicción financiera, mostrando mejores resultados en comparativa con métodos de predicción como el ARIMA y el Media Móvil Autoregresiva Integrada Estacional (SARIMA) [20].

En particular, se han utilizado para predecir el valor que tendrá en el futuro una acción en la bolsa de valores o proponiendo resaltar ciertas características de la serie de tiempo financiera y que sea clave en los hiperparámetros de la red [21].

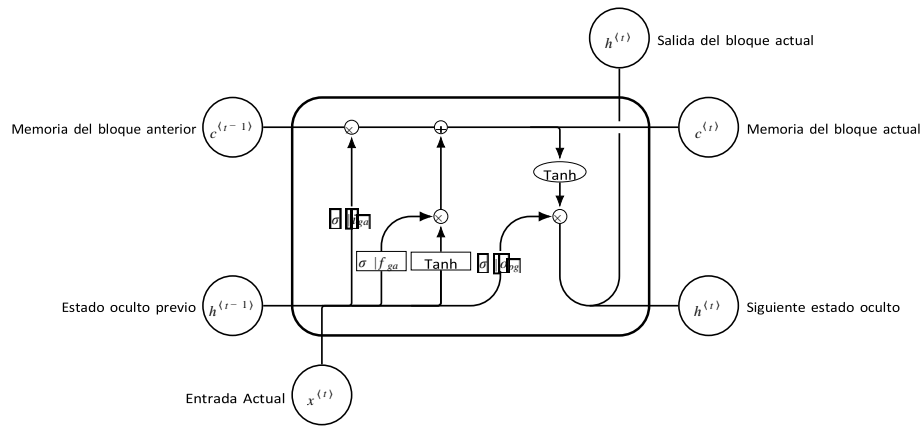


Fig. 1. Estructura de una celda de Red Neuronal Artificial Long Short-Term Memory (LSTM)

III. MÉTODOS DE PREDICCIÓN

A. Método LPC

Retomando parte del trabajo en [3], es posible observar que el análisis LPC está construido a partir de la combinación lineal de sus muestras en instantes anteriores. Así, la señal predicha se puede expresar como la ecuación (1):

$$\hat{s}(n) = - \sum_{k=1}^p a_k s(n - k). \quad (1)$$

Por otra parte, para llevar a cabo el cálculo del error entre la señal original y la predicción, se puede realizar empleando la ecuación (2):

$$e(n) = s(n) - \hat{s}(n), \quad (2)$$

donde $s(n)$ se puede considerar como la señal original, $\hat{s}(n)$ como la señal calculada, a_k son los coeficientes de predicción, p es el orden del filtro de predicción y $e(n)$ es el error de predicción.

Sustituyendo la ecuación (1) en (2), es posible redefinir el error como la ecuación (3):

$$e(n) = s(n) + \sum_{k=1}^p a_k s(n - k). \quad (3)$$

Al hacer uso de la transformada Z para el cálculo del error en tiempo discreto, se obtiene la ecuación (4):

$$E(z) = S(z) \left[1 + \sum_{k=1}^p a_k z^{-1} \right], \quad (4)$$

por lo que, es posible definir el término $A(z)$ como se expresa en la ecuación (5):

$$A(z) = \frac{E(z)}{S(z)} = 1 + \sum_{k=1}^p a_k z^{-1}. \quad (5)$$

Haciendo uso del error de predicción en un sistema con función de transferencia $1/A(z)$, se obtiene como salida a la señal deseada. En este modelo de predicción, se asume que $H(z)$ sigue un modelo todo-polos con q polos, obteniendo la ecuación (6):

$$H(z) = \frac{S(z)}{U(z)} = \frac{G}{1 + \sum_{k=1}^p a_k z^{-1}}. \quad (6)$$

Al identificar $H(z)$ con el filtro de predicción lineal $1/A(z)$ y asumiendo que el número de polos es igual al orden de predicción lineal, $p = q$ es posible obtener la función de transferencia representada por la ecuación (7):

$$H(z) = \frac{G}{A(z)}, \quad (7)$$

donde G es la ganancia del predictor y $E(z) = GU(z)$.

Es posible obtener la función de transferencia $H(z)$ a partir del cálculo de los coeficientes a_k . Como esta $H(z)$, que representa los parámetros de la señal, se modela como $1/A(z)$, el error de predicción representa la excitación.

Por tanto, el objetivo del método es encontrar el conjunto de coeficientes a_k que minimicen el error cuadrático medio en cada trama de análisis.

B. Método LSTM

El modelo de la red LSTM consta de 3 etapas, se menciona en [20]. La primera consiste en la colección de los datos y su preprocesamiento. La segunda etapa representa la implementación del modelo mediante la definición de una capa de LSTM y una capa densa. Finalmente, la tercera etapa muestra la predicción de los datos de validación utilizando el modelo ajustado a los datos de entrada y la evaluación de la predicción realizada.

En este modelo es posible identificar tres puertas: la puerta de entrada, la puerta de olvido y la puerta de salida. Todas las puertas emplean la función de activación sigmoide, como se puede observar en la Fig. 1.

En [19], se hace uso del modelado matemático para definir cada una de las etapas de una celda LSTM. Para la primera puerta que consiste en la información nueva que entra a la celda de estado, es posible ser modelada con la ecuación (8):

$$i_{ga} = \sigma(W_{ip}[h_{t-1}, X_t] + b_i). \quad (8)$$

Por otra parte, la puerta de olvido que permite eliminar la información que no es necesaria para realizar el proceso predicción del siguiente dato necesario, queda definida por la ecuación (9):

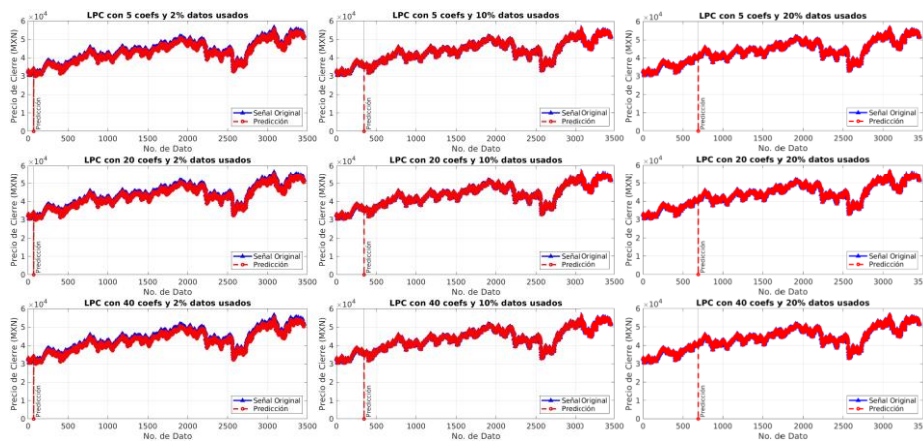


Fig. 2. Predicción del S&P/BMV IPC con LPC; 5, 20 y 40 coeficientes para 2%, 10% y 20% de datos usados de la base de datos

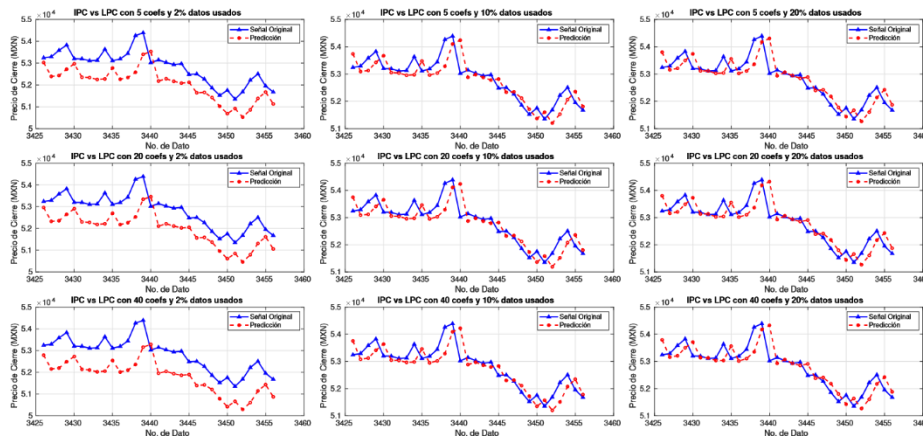


Fig. 3. Gráficas de predicción del S&P/BMV IPC de las últimas 30 muestras de las series de tiempo con LPC; 5, 20 y 40 coeficientes para 2%, 10% y 20% de datos usados de la base de datos

TABLA I
RMSE DE LAS PREDICIONES REALIZADAS CON LPC

Número de coeficientes	Porcentaje de datos usados		
	2%	10%	20%
5	1001.04	733.66	787.92
10x	1037.47	733.96	788.13
20	1141.46	735.15	788.5

$$f_{ga} = \sigma(W_{fg}[h_{t-1}, X_c] + bf). \tag{9}$$

Finalmente, la puerta de salida, la cual se activará hasta el último bloque de salida, definida por la ecuación (10):

$$o_{pg} = \sigma(W_{op}[h_{t-1}, X_c] + b_o), \tag{10}$$

donde σ es la función de activación es del tipo sigmoide, W_x es peso sináptico asignado a la puerta de la neurona (x), h_{t-1} es el resultado del bloque LSTM anterior, X_t es la entrada de datos al bloque LSTM y b_x es el bias del bloque.

IV. PRUEBAS DE EXPERIMENTACIÓN

A. Base de datos

La base de datos se encuentra conformada por 3,456 tuplas, con una fecha inicial del 04 de enero del 2010 al 22 de

septiembre del 2023, tomando como serie de tiempo principal el valor del precio de cierre de una jordana y publicados, de manera gratuita para cualquier interesado, en medios como Yahoo! Finance y Investing.com.

B. Pruebas con LPC

Para realizar las pruebas de predicción, se utilizó el software MATLAB™(versión 2023b) en una computadora con procesador Intel™Core i7-8700K, 16 GB de memoria RAM y tarjeta NVIDIA™1070 ti. Con este hardware y el uso del software fue posible aplicar un filtro generado a partir de diferentes configuraciones del método a una serie de tiempo.

Para tener un amplio panorama de los resultados, se realizaron pruebas con tres cantidades de coeficientes (5, 20 y 40) y tres porcentajes de la base de datos (2%, 10% y 20%). Estos porcentajes se utilizaron para determinar los valores de los coeficientes.

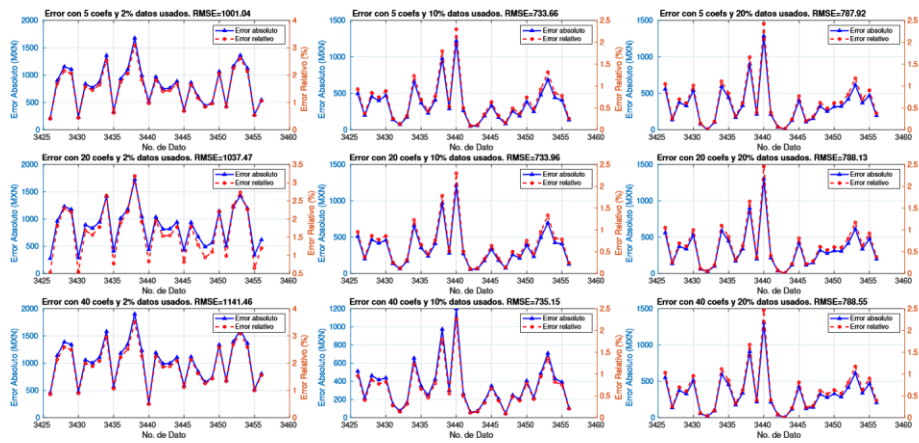


Fig. 4. Gráficas de los errores absolutos y errores relativos con 5, 20 y 40 coeficientes para 2%, 10% y 20% de la base de datos y mencionan los respectivos RMSE




Fig. 5. Arquitectura para red neuronal LSTM propuesta a partir del uso de Deep Network Designer de MATLAB

Para ello, se utiliza la función `lpc()`, que calcula los coeficientes del filtro LPC a partir de un conjunto de datos de entrenamiento. Una vez calculados los coeficientes, se pueden utilizar para predecir el valor futuro de la serie de tiempo. El uso del filtro LPC para predicción se puede resumir en los siguientes pasos: tener el conjunto de datos para el entrenamiento, utilizar la función `lpc()` para calcular los coeficientes del filtro y utilizarlos para predecir el valor futuro de la serie de tiempo.

La Fig. 2 muestra las gráficas de los datos originales y la predicción realizada con diferentes números de coeficientes. La predicción se muestra como una superposición de la señal original, lo que se puede observar en los valles de la serie de tiempo que llegan a 0 y luego vuelven a valores cercanos a la señal original los cuales representan el inicio de la predicción.

En todas las configuraciones, la predicción tiene un desfase debido a la naturaleza del modelo, que combina linealmente muestras anteriores. Este desfase podría solucionarse modificando los índices de los arrays generados, pero en este trabajo se decidió no realizar ningún cambio adicional, por lo que el desfase se mantiene en todas las gráficas.

En la Fig. 2 se observa que, en general, las predicciones siguen la tendencia de los datos originales. Para visualizar el desfase mencionado y comparar mejor ambas series, la Fig. 3 muestra las últimas 30 muestras de cada gráfica.

Para validar el error de la predicción, se calcularon los errores absolutos, relativos y cuadráticos medios (RMSE) para cada combinación de datos. La Fig. 4 muestra gráficamente los

errores para las últimas 30 muestras de cada serie de tiempo, así como el valor del RMSE para cada predicción.

Es posible observar en la Fig. 4, de manera general, que los errores en las diferentes combinaciones para la predicción del S&P/BMV IPC son cercanos al 2% (en el peor de los casos al 4%). Así mismo, el hecho de que exista una mayor cantidad de coeficientes lineales en el diseño del filtro LPC, así como una mayor cantidad de datos para la definición de los valores de dichos coeficientes, no significa que los resultados muestren una disminución en el error.

Los valores RMSE para la predicción, se visualizan en la Tabla 1. El menor RMSE se encuentra en el punto medio de las propuestas respecto al número de coeficientes y el porcentaje de datos (10 coeficientes y 10% de la base de datos utilizada), y muestra el menor error cuadrático medio (RMSE) en comparación con todos los demás.

C. Pruebas con LSTM

A partir del uso de hardware y software antes descrito, se realizaron las pruebas de predicción al aplicar a la serie de tiempo el diseño de una red neural LSTM.

El diseño e implementación de este tipo de red se llevó a cabo a partir de la herramienta Deep Network Designer cuya arquitectura final es la que se muestra en la Fig. 5. En dicha arquitectura se propone un bloque de entrada para el ingreso de una serie de tiempo, una capa LSTM que permite aprender dependencias a largo plazo entre pasos de tiempo en serie de tiempo y datos de secuencias, una capa dropout para establecer aleatoriamente los elementos de entrada, una capa fully

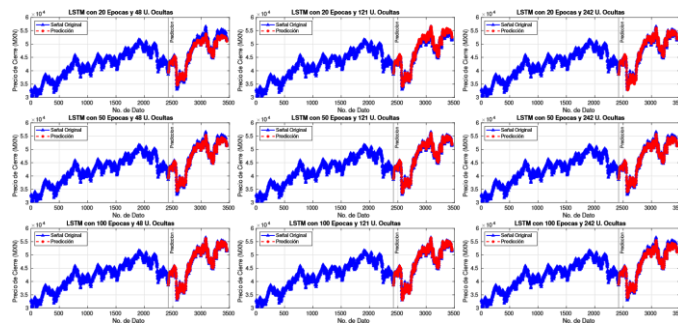


Fig. 6. Predicción del S&P/BMV IPC haciendo uso de la red neuronal artificial con variación en el número de épocas (20, 50 y 100) y las unidades ocultas en la capa LSTM (48, 121 y 242)




Fig. 7. Gráficas de la predicción del S&P/BMV IPC de las últimas 30 muestras de las series de tiempo, haciendo uso de la red neuronal artificial LSTM con variación en el número de épocas (20, 50 y 100) y las unidades ocultas en la capa LSTM (48, 121 y 242)

TABLA II
RMSE DE LAS PREDICIONES REALIZADAS CON LSTM.

Número de épocas	Número de unidades ocultas		
	48	121	242
20	1095.12	931.34	826.13
50	774.07	693.17	704.25
100	555.20	603.17	748.51

connected que multiplica por una matriz de peso y luego agrega un vector de polarización, y una capa de salida de regresión que calcula la pérdida del error cuadrático medio dividido de las tareas de regresión.

Para tener un amplio panorama sobre la experimentación, se realizó un banco de pruebas en donde se definieron algunas opciones para el entrenamiento.

Entre ellas, se hizo uso de un optimizador de entrenamiento de estimación de momento adaptativo Adam, con un Learn Rate de 0.005, un Batch size de 128, un Gradient Threshold de 1, un Max Epochs con 3 valores diferentes de 20, 50 y 100; y un Num Hidden Units también con tres valores diferentes tomando como base bloques definidos con respecto a la longitud de la serie de tiempo dividido entre 50, 20 y 10 teniendo hidden units, para este caso específico, de 48,121 y 242.

Además, se hizo uso de un proceso de normalización de los datos de la serie de tiempo original descrita por la ecuación (11):

$$X_n = \frac{X - \mu}{\sigma}, \tag{11}$$

donde X_n es la serie de tiempo normalizada, X es la serie de tiempo original, μ es el promedio de valores de la serie de tiempo original y σ es la desviación estándar de la serie de tiempo.

En la Fig. 6 se observan las gráficas de los datos originales contra la predicción realizada a partir de las diferentes combinaciones entre las épocas de entrenamiento y las unidades ocultas de la capa LSTM.

Cabe mencionar que, en cada iteración, la red actualiza sus valores para poder predecir el siguiente.

Nuevamente, es posible percibir un desplazamiento el cual podría solucionarse modificando los Índices de los arrays generados, pero en este trabajo se decidió no realizar ningún cambio adicional, por lo que el desfase se mantiene en todas las gráficas.

En la Fig. 6 puede observarse que las predicciones siguen la tendencia de los datos originales, aunque en algunos casos se

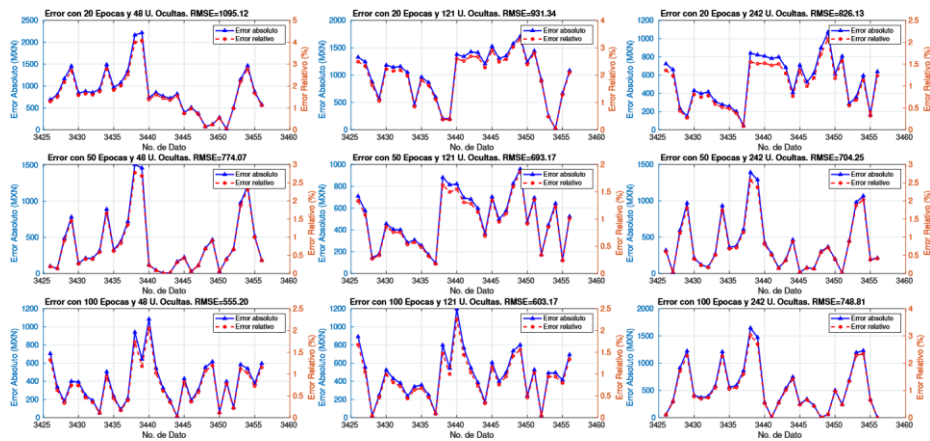


Fig. 8. Gráficas de los errores absolutos y errores relativos con la variación en el número de épocas (20, 50 y 100) y las unidades ocultas en la capa LSTM (48, 121 y 242). Así mismo, se mencionan los respectivos errores cuadráticos medios (RMSE) para cada una

percibe cierta diferencia entre la predicción y los datos originales. Para visualizar el desfase mencionado y una mejor observación de la comparativa entre ambas series, en la Fig. 7 se muestran las últimas 30 muestras de cada una de las gráficas anteriores.

Para validar el error de la predicción respecto de los datos originales, se realizó el cálculo errores absolutos y relativos; así como del RMSE para cada una de las combinaciones mostradas, similar que en el caso de la predicción con el método LPC.

La Fig. 8 muestra de manera gráfica cada uno de los errores previamente mencionados para las últimas 30 muestras de cada serie de tiempo.

En la Fig. 8, puede observarse que, a diferencia del LPC, los errores presentados, en algunos son menores del 4%; sin embargo, se debe tener presente que ante un mayor número de épocas de entrenamiento puede representar un problema debido al sobreajuste en la red.

Por otra parte, los resultados del cálculo del RMSE para este método fueron aún menores, lo que se puede observar en la Tabla 2.

V. CONCLUSIONES Y TRABAJO FUTURO

La gestión financiera es un tema de gran importancia para el desarrollo sostenible de cualquier región económica. En este trabajo, se evaluó la eficacia de dos métodos de predicción, el LPC y el LSTM, en el análisis y pronóstico del S&P/BMV IPC.

Los resultados indican que ambos métodos son eficaces para predecir las tendencias del mercado financiero mexicano, tras su obtención de errores relativos por debajo del 5%, cada uno con ciertas particularidades en el desarrollo de la predicción deseada.

Estos hallazgos son relevantes para la toma de decisiones informadas en entornos urbanos y pueden contribuir a mejorar la planificación económica y el desarrollo sostenible de cualquier región.

A partir de los datos mostrados en la Fig. 4 se puede decir que el método LPC permite obtener predicciones que, si bien presenta errores relativos de menos del 4%, puede emplearse como una primera aproximación. Por otra parte, en los datos mostrados en la Fig. 8 se pueden observar mejores resultados, con errores relativos menores de hasta el 2%, en la predicción

derivados del entrenamiento y las características de la red neuronal empleada.

Para este caso, parte del proceso de interés, más allá de comparar 2 métodos de predicción, también repercute en la visión de ellos, debido a que el método LPC, además de estar dentro de los métodos paramétricos, sólo requieren un número reducido de información previa (probado con sólo el 2% de los datos para la generación de los coeficientes del predictor), por lo que pueden usarse, con las consideraciones necesarias, en entornos con en los que no se cuenta con grandes bases de datos.

Por otra parte, la red neuronal LSTM, al estar dentro de los métodos no paramétricos y por la naturaleza de su arquitectura, requiere un número considerable de datos para realizar su entrenamiento (probado con el 70% de los datos para el entrenamiento y el 30% para su predicción), además de requerir un mayor tiempo para cumplir con su objetivo. Aunque, este método brinde una mayor exactitud en el proceso de predicción tras su visualización en menores valores de RMSE.

Otra posibilidad para trabajo futuro sería explorar alguno de los métodos mencionados previamente o ser aplicados en otros espacios y modelados de los métodos empleados en este trabajo, como el hecho de probar el método LPC o una red neuronal LSTM en una computadora cuántica llevando la respectiva adaptación necesaria. Esto permitiría incluir información de diversas fuentes, además de la información obtenida de portales bursátiles, como lo son las redes sociales, portales de gobierno, entre otros.

Es así como este trabajo demuestra que la predicción, bajo una visión de finanzas, es posible a partir de uso de modelos de predicción como LPC y LSTM en el análisis y pronóstico del S&P/BMV IPC. Además, destaca la importancia de las herramientas de predicción al promover prácticas responsables y sostenibles en esta área de estudio.

A. Base de datos disponible

La base de datos se puede consultar en https://github.com/LuisGorjoux1/Pred_IPC_LEAG/blob/main/Datos_SP_BMV_IPC10a22/Datos_SP_BMV_IPC_100101a2_30922.csv.

REFERENCIAS

- [1]. F. Rodríguez, “Análisis técnico de los mercados financieros”, Universidad de Valladolid. https://uvadoc.uva.es/bitstream/handle/10324/46903/TFG-E-1_202.pdf. (2021).
- [2]. Organización de las Naciones Unidas, Objetivos y metas de desarrollo sostenible. <https://www.un.org/sustainabledevelopment/es/sustainable-development-goals/> (2023).
- [3]. Y. Galve and A. Miguel, “Diseño de herramientas de asistencia a la logopedia en una plataforma distribuida”. Universidad de Zaragoza. <https://core.ac.uk/download/pdf/289972235.pdf> (2012).
- [4]. J. Kim, H.S. Kim and S.Y. Choi, “Forecasting the S&P 500 Index Using Mathematical-Based Sentiment Analysis and Deep Learning Models: A FinBERT Transformer Model and LSTM”, *Axioms*, vol. 12, no. 9, pp. 835, (2023). DOI: 10.3390/axioms12090835.
- [5]. X. Fu, “Research on artificial intelligence classification and statistical methods of financial data in smart cities,” *Computational Intelligence and Neuroscience*, (2022).
- [6]. P. Dobos, K. Takács-Gyorgy, “Possible Smart City Solutions in the Fight against Black Economy,” *Interdisciplinary Description of Complex Systems: INDECS*, vol. 17, no. 3-A, pp. 468–475. (2019).
- [7]. M. Blanck, J.L.D. Ribeiro, “Smart cities financing system: An empirical modelling from the European context,” *Cities*, vol. 116, no. 103268 (2021).
- [8]. C. Papa, N. Rossi, “Smart Cities and Sustainable Finance,” *European Journal of Islamic Finance*, vol. 9, no. 2, pp. 18–26, (2022).
- [9]. M.A. Nikouei, S.S. Darvazeh and M. Amiri, “Artificial Intelligence and Financial Markets in Smart Cities,” In: *Data-Driven Mining, Learning and Analytics for Secured Smart Cities: Trends and Advances*, pp. 313–332, Springer International Publishing, (2021).
- [10]. D. An, N. Linden, J. Liu, A. Montanaro, C. Shao and J. Wang, “Quantum accelerated multilevel Monte Carlo methods for stochastic differential equations in mathematical finance,” (2021). DOI: 10.22331/q-2021-06-24-481.
- [11]. X. Tang, S. Xu and H. Ye, “The Way to Invest: Trading Strategies Based on ARIMA and Investor Personality,” *Symmetry*, vol. 14, no. 11, pp. 2292, (2022).
- [12]. X. Zhong and D. Enke, “Predicting the daily return direction of the stock market using hybrid machine learning algorithms,” vol. 5, no. 1, (2019). DOI: 10.1186/s40854-019-0138-0.
- [13]. M.B. Salas, D. Alaminos, M.A. Fernández and F. López-Valverde, “A global prediction model for sudden stops of capital flows using decision trees,” *Plos one*, vol. 15, no. 2, pp. e0228387, (2020).
- [14]. W. Khan, U. Malik, M. Ghazanfar, M. Azam, K. Alyoubi, and A. Alfakeeh, “Predicting stock market trends using machine learning algorithms via public sentiment and political situation analysis,” (2019). DOI: 10.1007/s00500-019-04347-y.
- [15]. S. Chen, “Quantum Long Short Term Memory,” (2022). <https://www.osti.gov/servlets/purl/1842795>.
- [16]. G. Verdon, M. Broughton, J. McClean, K. Sung, R. Babbush, H. Neven, and M. Mohseni, “Learning to learn with quantum neural networks via classical neural networks,” (2019).
- [17]. D. Reid, A.J. Hussain and H. Tawfik, “Financial time series prediction using spiking neural networks,” *PloS one*, vol. 9, no. 8, (2014).
- [18]. L. Mello, “Linear Predictive Coding as an Estimator of Volatility,” arXiv preprint cs/0607107, (2006).
- [19]. G. Sonkavde, D.S. Dharrao, A.M. Bongale, S.T. Deokate, D. Doreswamy and S.K. Bhat, “Forecasting Stock Market Prices Using Machine Learning and Deep Learning Models: A Systematic Review, Performance Analysis and Discussion of Implications,” *International Journal of Financial Studies*, vol. 11, no. 3, pp. 94, (2023).
- [20]. U.M. Sirisha, M.C. Belavagi, and G. Attigeri, “Profit prediction using Arima, Sarima and LSTM models in time series forecasting: A Comparison,” *IEEE Access*, vol. 10, pp. 124715–124727, (2022).
- [21]. F.J. Pedroza-Castro, A.R. Domínguez, M. Carpio, M. Ornelas-Rodríguez, and H. Puga, “Optimización de hiperparámetros de una red Long Short Term Memory para pronósticos financieros,” *Research in Computing Science*, vol. 151, no. 7, pp. 123139. (2022).