

Implementación de una red neuronal LSTM a un proyecto de Inteligencia de Negocios con énfasis en datos económicos: Avance de resultados.

Carlos Alberto Baltazar Vilchis
Centro Universitario Atlaconulco
Universidad Autónoma del Estado de México
Atlaconulco, Estado de México
cabaltazarv@uaemex.mx

Yenit Martínez Garduño
Centro Universitario Atlaconulco
Universidad Autónoma del Estado de México
Atlaconulco, Estado de México
ymartinezg@uaemex.mx

Alberto Garduño Martínez
Centro Universitario Atlaconulco
Universidad Autónoma del Estado de México
Atlaconulco, Estado de México
agardunom@uaemex.mx

Resumen— El presente artículo expone un avance de resultados derivado del análisis de la inflación en México desde su inicio en 1969 hasta la fecha actual, utilizando técnicas de Inteligencia de Negocios. Se efectuó un pronóstico a partir del 1 de diciembre de 2021, el cual se mantuvo preciso durante un período de 22 meses. Sin embargo, a partir del 1 de noviembre de 2022, el pronóstico comenzó a desviarse de manera significativa, contraviniendo las expectativas teóricas. Con el objetivo de abordar esta discrepancia y fortalecer la metodología empleada, se ha iniciado el desarrollo de un modelo de Inteligencia Artificial basado en una Red Neuronal de Memoria a Corto y Largo Plazo, utilizando la plataforma Anaconda versión 23.5.0 que incorpora Python 3.11.3 y Jupyter Notebook 3.9. Este enfoque tiene por finalidad prever posibles escenarios económicos a finales de 2024, que constituye el alcance actual de la presente investigación. Los resultados de esta investigación seguramente desempeñarán un papel crucial en la toma de decisiones a nivel individual, empresarial y gubernamental, dado que la estabilidad económica de dichas entidades depende en gran medida de la capacidad para anticipar y mitigar los efectos de la inflación. Cabe destacar que el modelo se encuentra actualmente en fase de entrenamiento.

Palabras Clave— *Prospectiva, Inteligencia Artificial, Inteligencia de Negocios, Red Neuronal de Memoria a Corto y Largo Plazo*

Abstract— The present article presents an advance of results derived from the analysis of inflation in Mexico from its inception in 1969 to the present date, using Business Intelligence techniques. A forecast was made starting on December 1, 2021, which remained accurate for a period of 22 months. However, from November 1, 2022, the forecast began to deviate significantly, contrary to theoretical expectations. In order to address this discrepancy and strengthen the methodology employed, the development of an Artificial Intelligence model based on a Long Short-Term Memory Neural Network has been initiated, using the Anaconda platform version 23.5.0, which incorporates Python 3.11.3 and Jupyter Notebook 3.9. This approach aims to predict possible economic scenarios at the end of 2024, which is the current scope of the present research. The results of this research will likely play a crucial role in decision-making at the individual, corporate, and governmental levels, as the economic stability of these entities depends largely on the ability to anticipate and mitigate the effects of inflation. It is worth noting that the model is currently in the training phase.

Keywords— *Foresight, Artificial Intelligence, Business Intelligence, Long-Short Term Memory.*

I. INTRODUCCIÓN

En la era contemporánea, la convergencia de la tecnología y la economía ha generado un impacto transformador en la manera en que se comprenden, analizan y pronostican las variables económicas. La inteligencia artificial (IA), una disciplina que busca replicar la capacidad humana de razonamiento y aprendizaje en sistemas informáticos ha emergido como una herramienta fundamental en el análisis de variables económicas. Esta sinergia entre la IA y la economía ha abierto nuevas perspectivas para comprender las complejas interacciones que impulsan los mercados, el comportamiento de los consumidores, las tendencias macroeconómicas y la toma de decisiones estratégicas en un mundo cada vez más interconectado.

La inteligencia artificial, en su forma más básica, se basa en algoritmos y modelos matemáticos que permiten a las máquinas procesar y analizar grandes volúmenes de datos de manera eficiente y rápida. Esta capacidad de procesamiento ha revolucionado la forma en que se abordan las cuestiones económicas. En lugar de depender exclusivamente de modelos teóricos estáticos, ahora es posible integrar datos en tiempo real y utilizar algoritmos avanzados para detectar patrones, correlaciones y tendencias ocultas en los datos económicos. Esto proporciona a los economistas y analistas una visión más precisa y actualizada de la realidad económica, permitiéndoles tomar decisiones más informadas.

Uno de los campos donde la inteligencia artificial ha demostrado un impacto significativo es en el análisis de datos financieros y predicción de mercados. Los algoritmos de aprendizaje automático pueden analizar históricos de precios, volúmenes de transacciones y noticias relevantes para identificar patrones que los humanos podrían pasar por alto. Estos modelos pueden ayudar a predecir movimientos del mercado y tomar decisiones de inversión más fundamentadas.

Además, la inteligencia artificial ha permitido avances notables en la personalización de experiencias para los consumidores. A través del análisis de datos de comportamiento y preferencias, las empresas pueden adaptar sus ofertas y estrategias de precios de manera más precisa, aumentando la satisfacción del cliente y optimizando sus resultados económicos.

No obstante, la aplicación de la inteligencia artificial a las variables económicas no está exenta de desafíos. La interpretación de resultados de modelos de IA puede ser compleja, y existe la preocupación de que la automatización

excesiva pueda llevar a la exclusión de ciertos grupos o a la toma de decisiones opacas. Además, la calidad de los resultados depende en gran medida de la calidad de los datos utilizados y de la elección adecuada de los algoritmos.

Por otro lado, la Inteligencia de Negocios (Business Intelligence en anglosajón y sus siglas en inglés son BI) se refiere a un conjunto de herramientas, procesos y tecnologías que permiten a las organizaciones recopilar, analizar y presentar datos para facilitar la toma de decisiones empresariales informadas. El objetivo principal del BI es transformar los datos en información significativa, como informes, paneles de control y visualizaciones, que los tomadores de decisiones pueden utilizar para comprender mejor el rendimiento empresarial, identificar tendencias, detectar patrones y evaluar el impacto de las decisiones previas. El BI se basa en datos históricos y se centra en el análisis descriptivo y predictivo.

La IA se utiliza cada vez más en el campo del BI para mejorar la calidad de los análisis y las decisiones empresariales. Algunas formas en que la IA se integra en el BI incluyen:

- Automatización: La IA puede automatizar tareas de análisis de datos, como la limpieza y el procesamiento de datos, lo que ahorra tiempo y reduce errores.
- Análisis avanzado: La IA puede identificar patrones y tendencias en los datos que pueden ser difíciles de detectar mediante métodos tradicionales de BI.
- Predicciones y recomendaciones: La IA puede proporcionar análisis predictivos y prescriptivos, lo que permite a las organizaciones anticipar eventos futuros y tomar decisiones proactivas.
- Procesamiento del lenguaje natural: La IA se utiliza en la extracción de información de texto no estructurado, lo que permite a las empresas analizar opiniones de clientes, comentarios en redes sociales y otros datos no tabulares.

En definitiva, la intersección entre la Inteligencia Artificial y la Inteligencia de Negocios aplicado al estudio de variables económicas prometen revolucionar la forma en que se abordan y comprenden los fenómenos económicos. A medida que se continúa avanzando en esta era digital, es esencial explorar cómo la IA puede mejorar la capacidad para predecir, analizar y responder a los desafíos económicos y financieros en constante evolución.

II. ESTADO DEL ARTE

Cuando se comienza a estudiar la aplicabilidad de la Inteligencia Artificial (IA) en cuestiones económicas uno de los autores que destacan es Ajay Agrawal quien ha realizado contribuciones significativas a la comprensión de cómo ésta impacta en la economía y la toma de decisiones empresariales. Agrawal ha promovido un enfoque monetario para comprender el valor y el impacto de la IA en los negocios y la sociedad en general. Su trabajo se centra en cómo estas tecnologías transforman la forma en que se toman las decisiones y cómo las organizaciones pueden aprovechar estas transformaciones para obtener ventajas competitivas. [1] [2]

Susan Athey, reconocida economista, ha realizado contribuciones valiosas a la intersección entre la inteligencia artificial y la economía. Sus aportes incluyen investigaciones sobre el impacto de algoritmos y plataformas digitales en la competencia y los mercados, así como el desarrollo de métodos estadísticos avanzados para analizar datos en entornos digitales. Athey también ha explorado la economía de la publicidad en línea, la asignación eficiente de recursos mediante subastas y la integración de técnicas de aprendizaje automático en la estimación causal. Su enfoque en la economía experimental en línea y la influencia de la información en entornos digitales complementan su destacada labor en la comprensión de cómo la inteligencia artificial moldea la toma de decisiones y la economía contemporánea. [3] [4]

Hal Varian, economista y estratega en jefe de Google, ha dejado una huella significativa en el estudio y aplicación de la IA. Sus principales aportes incluyen investigaciones sobre la economía de la información y cómo la IA impacta en la toma de decisiones y la competencia en entornos digitales. Además, ha explorado cómo los algoritmos y la IA pueden influir en la economía de las plataformas digitales y en la forma en que las empresas optimizan sus estrategias. Su enfoque en la intersección entre la tecnología y la economía ha proporcionado una visión esencial sobre cómo la IA transforma la economía y la sociedad en general. [5] [6]

Erik Brynjolfsson, reconocido académico y autor, ha realizado contribuciones clave al estudio y aplicación de la IA. Su enfoque en la economía de la tecnología ha arrojado luz sobre cómo la IA impacta en la productividad, la innovación y la economía en general. Brynjolfsson ha investigado cómo la automatización y la IA transforman la fuerza laboral y las estructuras empresariales, destacando la necesidad de adaptación y políticas adecuadas. Además, su trabajo sobre la "Edad de la Máquina" ha impulsado la comprensión de cómo la tecnología, incluida la IA, redefine el crecimiento económico y la sociedad en la era digital, convirtiéndolo en un influyente pensador sobre la intersección entre la tecnología y la economía. [7] [8]

Joshua Gans, renombrado académico, ha realizado contribuciones esenciales al estudio y la aplicación de la Inteligencia Artificial. Su enfoque en la economía de la información y la estrategia empresarial ha brindado perspicacia sobre cómo la IA transforma la toma de decisiones y la competencia en diversos sectores. Ha explorado cómo impacta en la innovación y cómo las empresas pueden adaptar sus estrategias para capitalizar estas transformaciones. Su trabajo también ha abordado la intersección entre la IA y la economía de las plataformas digitales, ilustrando cómo remodela la relación entre proveedores y consumidores. En última instancia, Gans ha enriquecido la comprensión de cómo la IA moldea la economía moderna y cómo las organizaciones pueden aprovechar su potencial. [9] [10]

Daron Acemoglu, prominente economista, ha realizado contribuciones fundamentales al estudio y aplicación de la Inteligencia Artificial (IA). Su enfoque en la economía política y la tecnología ha brindado una comprensión

profunda de cómo la IA y la automatización pueden impactar en la desigualdad, el empleo y las instituciones económicas. Acemoglu ha investigado cómo la adopción de la IA puede alterar la distribución de la riqueza y el poder, ha examinado la importancia de las políticas y regulaciones para mitigar los posibles efectos negativos. Su trabajo ha contribuido a las discusiones sobre cómo las sociedades pueden equilibrar los beneficios y los desafíos de la IA para lograr un desarrollo sostenible y equitativo. [11] [12]

Por otra parte, si bien es cierto que el término Business Intelligence fue propuesto por Richard Miller Devens en 1868 [13] cuando citó a un banquero que recopilaba de forma manual información sobre el mercado antes que sus competidores y que fue hasta 1958 cuando un científico informático de IBM llamado Hans Peter Luhn escribió un artículo en el que describía el potencial de recopilar BI mediante el uso de tecnología [14], sería hasta 1989 cuando Howard Dresner popularizó el concepto de "Inteligencia de Negocios", como un término "paraguas" para describir "los conceptos y métodos para mejorar la toma de decisiones empresariales mediante el uso de sistemas basados en hechos de apoyo". [15]

En cuanto a las contribuciones que fundamentarán teóricamente la presente propuesta se tienen las siguientes:

A. Modelo basado en redes neuronales recurrentes LSTM para la predicción de la siguiente actividad en procesos de negocio. [16]

Se plantea un enfoque para aplicar la arquitectura de red neuronal recurrentes de tipo Memoria a Corto y Largo Plazo (LSTM) en el contexto de la minería de procesos. La metodología implicó entrenar la LSTM utilizando diversos conjuntos de registros de eventos, con el propósito de comparar su nivel de precisión. Estos registros de eventos exhibieron variaciones en la cantidad de trazas, el número de casos y el total de actividades registradas. La tasa de exactitud alcanzada durante el proceso de entrenamiento de la red LSTM se encuentra en línea con lo que la literatura especializada en este ámbito describe como aceptable. De igual manera, se valida la capacidad de la red para predecir con precisión la actividad siguiente con base en los resultados obtenidos.

B. Estimación adelantada del crecimiento regional mediante redes neuronales LSTM. [17]

Se propone la integración de métodos de Inteligencia Artificial en las herramientas existentes para examinar la situación actual de una región. Se efectúa una comparación entre las predicciones generadas mediante el uso de Redes de memoria a largo plazo, conocidas como LSTM y las técnicas convencionales. Los resultados indican que los progresos en las redes neuronales tienen la posibilidad de enriquecer el análisis de la coyuntura al mejorar las predicciones. Estas herramientas se complementan mutuamente, siendo las redes neuronales más adaptables para abordar diversas situaciones en la economía real, y demostrando una habilidad superior

para generar estimaciones (con menor margen de error cuadrático medio).

C. Red neuronal Long Short-Term Memory (LSTM) aplicada a series temporales para pronosticar consumo energético en edificaciones. [18]

En este estudio, se emplearon técnicas de aprendizaje automático supervisado mediante redes neuronales con el objetivo de predecir cómo se comportaría el consumo de energía en una residencia familiar. Para llevar a cabo esta tarea, se diseñó un experimento que se basó en un conjunto de datos que abarcó un período de casi cuatro años de mediciones de consumo energético. Durante el proceso de experimentación, se evaluaron cuatro arquitecturas diferentes de Redes Neuronales de Memoria a Corto y Largo Plazo (LSTM) y se ajustaron aproximadamente 200 modelos al variar los hiperparámetros. La evaluación se realizó utilizando métricas como el error cuadrático medio (RMSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE) con el propósito de comparar y seleccionar el modelo LSTM más adecuado. El resultado señaló que la mejor estructura LSTM consistía en una versión simple con salida vectorial.

D. Business Intelligence como estrategia para optimización de flujos de efectivo ante entornos emergentes. [19]

En la investigación se utilizó al Business Intelligence como metodología principal para la obtención de información en una microempresa, realizar su transformación y posteriormente la carga mediante el uso de un Micro Data Warehouse mediante el uso del programa MS Power BI, finalmente se lograron determinar los flujos de caja: desde el inicio operacional del negocio (desde enero de 2018) para definir la estrategia a seguir ante los actuales entornos emergentes afectados en ese entonces debido a la pandemia de COVID19, lográndose una toma de decisiones adecuada para la determinación de los principales productos a consumirse en el corto plazo por parte de los consumidores.

E. Business intelligence in academic libraries in Jordan: Opportunities and challenges. [20]

La Inteligencia de Negocios ofrece potentes herramientas analíticas, como herramientas de visualización y extracción de datos, que conducen a decisiones informadas y, por tanto, transforman la experiencia del usuario, llevándola a un nivel más avanzado. Esta investigación investiga el concepto de BI a partir de las percepciones del personal del departamento de información de las bibliotecas académicas de Jordania. Se discutieron y exploraron las oportunidades y desafíos asociados con esto. Uno de los principales resultados indicó que el personal del departamento de información coincide en que la Inteligencia de Negocio mejora la toma de decisiones, ayudar a los tomadores de decisiones a tomar las decisiones más precisas y oportunas para la biblioteca. Los resultados también indican que una infraestructura adecuada es importante para la implementación exitosa de BI.

F. *Aplicación de técnicas de inteligencia de negocios y análisis de datos en el entorno empresarial cubano: retos y perspectivas.* [21]

Se ofrece una descripción del empleo de sistemas informáticos en la administración y dirección de empresas en Cuba, exponiendo sus ventajas y desventajas actuales. También se efectúa un análisis cronológico de las herramientas más empleadas en el ámbito mundial para la inteligencia empresarial y el procesamiento de datos, señalando las más populares. Se introduce el sistema BIMAS, un sistema ejecutivo diseñado por DESOFT para la planificación estratégica y supervisión de su ejecución, junto con sugerencias para su desarrollo futuro. En resumen, se destaca la falta de demanda de este tipo de soluciones en el país y la necesidad de su implementación para mejorar la eficacia y eficiencia en la gestión empresarial.

III. METODOLOGÍA

La presente investigación se comenzó a desarrollar con la perspectiva de BI desde el 01/01/2021 con el monitoreo al Índice Nacional de Precios al Consumidor (INPC) de la página del Banco de México (Banxico) [22], en la Figura 1 se detalla su proceso. [23]

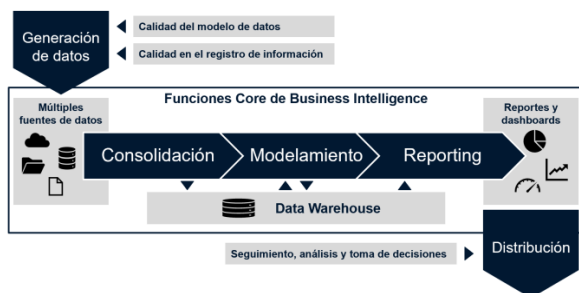


Figura 1. Funciones Core de Business Intelligence

Para medir el grado de efectividad del pronóstico se consideraron los datos comprendidos entre los años 1969 al 2021, posteriormente se realizó el pronóstico al año 2022 y 2023 donde se comparó con el valor más reciente real para determinar el porcentaje de efectividad, para ello se utilizó SPSS versión 25 de prueba y se aplicó el modelo ARIMA, muy utilizado en cuestiones económicas. [24] [25]

En cuanto al desarrollo de la red neuronal Long-Short Term Memory (LSTM) la literatura que se consultó sugiere una metodología de naturaleza empírica con el propósito de encontrar la estructura y modelo que se adapten de manera óptima al conjunto de datos bajo análisis, como se indica en la Figura 2, en este caso, se busca minimizar el error en las predicciones del INPC considerando un total de 655 registros mensuales desde el 1 de enero de 1969 al 1 de julio de 2023.

Se llevó a cabo un diseño experimental que incluyó tanto estructuras LSTM puras como híbridas, se exploraron diversas combinaciones de hiperparámetros para crear modelos que fueron evaluados utilizando el conjunto de datos de entrenamiento, el modelo más efectivo se someterá a validación empleando el conjunto de datos de evaluación, y se seleccionará en función de la métrica de error más baja.

La implementación de estos modelos de redes neuronales recurrentes se llevará a cabo mediante Anaconda v23.5.0 y Jupyter Notebook 6.5.3 utilizando códigos desarrollados en el lenguaje de programación Python 3.10, utilizado los paquetes Numpy que es una biblioteca fundamental en el ecosistema de Python que se utiliza para realizar operaciones matemáticas de manera eficiente y Pandas utilizada para el análisis y manipulación de datos, las redes LSTM de aprendizaje profundo han sido desarrolladas con Keras biblioteca facilita la creación de modelos para el aprendizaje profundo y construidas sobre TensorFlow, biblioteca de código abierto desarrollada por Google que se utiliza ampliamente en el campo del aprendizaje profundo y el procesamiento de datos. [16] [17] [18]



Figura 2. Metodología el desarrollo de la red LSTM.

A continuación, se proporciona una descripción paso a paso sobre el código generado para desarrollar la red neuronal LSTM:

Paso 1: Carga y Preparación de Datos

El código comienza por cargar datos, obtenidos de la página web del Banco de México, desde un archivo CSV llamado "valores.csv". Estos datos contienen registros de dos columnas: "FECHA" y "PRECIO".

La columna "FECHA" representa las fechas en un formato específico, y la columna "PRECIO" contiene los valores que ha tenido la inflación desde el 01/01/1969. Estos datos se cargan en un DataFrame de Pandas y se preparan para su procesamiento.

Paso 2: Filtrado de Datos

El código filtra los datos hasta la fecha "01/12/2021" para restringir el conjunto de datos a un período específico.

Paso 3: Normalización de Datos

Se normalizan los datos de la columna "PRECIO" utilizando la técnica Min-Max Scaling. Esto escalará los valores a un rango entre 0 y 1 para facilitar el entrenamiento de la red.

Paso 4: Creación de Secuencias de Datos

Los datos normalizados se convierten en secuencias de datos para el entrenamiento de la red. Se crea un conjunto de secuencias de datos de entrenamiento y las correspondientes "etiquetas" que se utilizarán para entrenar la red.

Paso 5: División en Conjuntos de Entrenamiento y Prueba

Se divide el conjunto de datos en conjuntos de entrenamiento y prueba. El 80% de los datos se asignan al conjunto de entrenamiento (X_train, y_train), mientras que el 20% se asignan al conjunto de prueba (X_test, y_test).

Paso 6: Creación del Modelo LSTM

Se define la arquitectura del modelo de red neuronal LSTM utilizando TensorFlow y Keras. El modelo consta de una capa LSTM con 50 unidades y una función de activación ReLU, seguida de una capa de salida densa con una sola neurona.

Paso 7: Entrenamiento del Modelo

El modelo se entrena utilizando los datos de entrenamiento. Se utilizan 50 épocas (iteraciones completas a través de los datos de entrenamiento) y un tamaño de lote de 32. Durante el entrenamiento, el modelo ajusta sus pesos para hacer predicciones más precisas.

Paso 8: Evaluación del Modelo

El modelo entrenado se evalúa utilizando los datos de prueba para calcular una métrica de pérdida (loss). La métrica de pérdida proporciona una medida de qué tan bien se ajusta el modelo a los datos de prueba.

Paso 9: Pronóstico de Valores Futuros

Se utiliza el modelo entrenado para realizar pronósticos de los valores de la columna "PRECIO" para un período futuro, desde el "01/01/2022" al "01/08/2023". Los pronósticos se realizan día a día, y se utiliza la salida de la red como entrada para pronósticos futuros.

Paso 10: Desnormalización de Resultados

Los valores pronosticados se desnormalizan para llevarlos de nuevo al rango original de precios.

Paso 11: Creación y Exportación de Resultados

Los resultados de los pronósticos se almacenan en un DataFrame de Pandas que incluye las fechas y los valores pronosticados. Luego, estos resultados se exportan a un archivo CSV llamado "resultadosOK.csv" en la ruta "C:/".

Paso 12: Impresión de Resultados Parciales

Finalmente, el código imprime los primeros registros del DataFrame de resultados para que el usuario pueda verificar los valores pronosticados.

IV. RESULTADOS

Durante 22 meses el modelo de Inteligencia de Negocios se encontró dentro de los parámetros adecuados conforme a la teoría, en la figura 3 se identifica esta situación.

N	PERIODO	INPC	PREDICCIÓN 21	REAL VS PRED	PREDICCIÓN 23	REAL VS PRED23
625	01/01/2021	110.21	109.7	-0.51		
626	01/02/2021	110.907	109.94	-0.967		
627	01/03/2021	111.824	110.17	-1.654		
628	01/04/2021	112.19	109.81	-2.38		
629	01/05/2021	112.419	109.64	-2.779		
630	01/06/2021	113.018	109.89	-3.128		
631	01/07/2021	113.682	110.31	-3.372		
632	01/08/2021	113.899	110.62	-3.279		
633	01/09/2021	114.601	110.98	-3.621		
634	01/10/2021	115.561	111.55	-4.011		
635	01/11/2021	116.884	112.22	-4.664		
636	01/12/2021	117.308	112.75	-4.558		
637	01/01/2022	118.002	113.27	-4.732		
638	01/02/2022	118.981	118.002	-0.979		
639	01/03/2022	120.159	119.87	-0.289		
640	01/04/2022	120.809	120.03	-0.779		
641	01/05/2022	121.022	120.31	-0.712		
642	01/06/2022	122.044	121.06	-0.984		
643	01/07/2022	122.948	122	-0.948		
644	01/08/2022	123.803	122.81	-0.993		
645	01/09/2022	124.571	123.73	-0.841		
646	01/10/2022	125.276	124.92	-0.356		
647	01/11/2022	125.997	126.29	0.293	126.2470533	0.2500533
648	01/12/2022	126.478	127.44	0.962	127.0313402	0.553340235
649	01/01/2023	127.336	128.75	1.414	128.0051973	0.66919734
650	01/02/2023	128.046	129.89	1.844	128.7969392	0.750939176
651	01/03/2023	128.389	131.07	2.681	129.6631274	1.274127405
652	01/04/2023	128.363	131.55	3.187	129.8369747	1.473974743
653	01/05/2023	128.084	132.19	4.106	130.0799357	1.995935669
654	01/06/2023	128.214	133.39	5.176	130.8931036	2.679103585
655	01/07/2023	128.832	134.81	5.978	131.8744781	3.042478076

Figura 3. Resultados obtenidos mediante BI y el modelo Arima.

En la figura 4 se identifica la distribución de los datos y la ecuación de la curva.




Figura 4. Gráfica del modelo BI con su ecuación.

En la tabla 1 se muestra el porcentaje de efectividad del modelo basado en BI

SUMA INPC REAL	3216.364
SUMA INPC PREDICCIÓN	3173.32566
ERROR	43.0383425
% EFECTIVIDAD	98.66%
% ERROR	1.34%

Tabla 1. Efectividad Modelo BI

Como se puede identificar, a partir del 01/11/2022 el pronóstico fue nuevamente calculado y a partir de ese instante el modelo ya no fue posible replicarlo, motivo por el cual se consideró el utilizar una Inteligencia Artificial y la revisión documental sugirió el uso de una red LSTM.

Los detalles sobre cómo se configuraron los parámetros de la red LSTM se encuentran presentados en la Tabla 2, que proporciona información sobre la configuración de esta red neuronal.

PARÁMETRO	VALOR
epochs	50
batch_size	20
optimizer	Adam
loss	mse
LSTM_units	50

Tabla 2. Parámetros de configuración de la red neuronal LSTM.

En la figura 5 se presenta un extracto del registro de eventos utilizado para entrenar la red neuronal LSTM.

```
Epoch 43/50
16/16 [=====] - 0s 3ms/step - loss: 0.8100
Epoch 44/50
16/16 [=====] - 0s 3ms/step - loss: 0.8301
Epoch 45/50
16/16 [=====] - 0s 3ms/step - loss: 0.8090
Epoch 46/50
16/16 [=====] - 0s 4ms/step - loss: 0.8220
Epoch 47/50
16/16 [=====] - 0s 3ms/step - loss: 0.8011
Epoch 48/50
16/16 [=====] - 0s 4ms/step - loss: 0.8487
Epoch 49/50
16/16 [=====] - 0s 3ms/step - loss: 0.7839
Epoch 50/50
16/16 [=====] - 0s 4ms/step - loss: 0.8483
<keras.src.callbacks.history at 0x2379bddd700>
```

Figura 5. Extracto de un registro de evento.

En la figura 6 se identifica la evaluación del modelo con los datos de prueba, indica que durante el entrenamiento de la red neuronal, el valor de pérdida en el conjunto de entrenamiento alcanzó 0.1140, y en el conjunto de prueba, el valor de pérdida fue similar, específicamente 0.11402852088212967. Esto sugiere que el modelo tiene un rendimiento consistente en el conjunto de entrenamiento y en un conjunto de datos de prueba, lo que es una señal positiva de que está aprendiendo de manera efectiva y generalizando bien. Sin embargo, siempre es importante considerar otras métricas y realizar una evaluación completa del modelo antes de tomar decisiones finales sobre su rendimiento.

```
# Evaluar el modelo con los datos de prueba
test_loss = model.evaluate(X_test, y_test)
print(f'Loss en datos de prueba: {test_loss}')

4/4 [=====] - 0s 4ms/step - loss: 0.1140
Loss en datos de prueba: 0.11402852088212967
```

Figura 6. Evaluación del Modelo.

V. CONCLUSIONES

El proyecto que involucra la implementación de una red neuronal LSTM para la predicción de series temporales se encuentra en una fase inicial y de ajustes. El trabajo presentado en este avance del proyecto ha proporcionado valiosas lecciones y resultados preliminares. Se ha demostrado la importancia de la preparación de datos, la normalización, la configuración de la arquitectura del modelo y la evaluación adecuada. Sin embargo, es crucial reconocer que aún se requieren más investigaciones y refinamientos antes de llegar a una solución final. En etapas posteriores del proyecto, se buscará afinar aún más los hiperparámetros del modelo, explorar diferentes arquitecturas de red, considerar la inclusión de características adicionales y realizar una validación exhaustiva en datos independientes. Este enfoque iterativo y de mejora continua permitirá desarrollar un modelo LSTM sólido y confiable para la predicción de series temporales que pueda tener aplicaciones prácticas en una variedad de campos, este avance es un primer acercamiento de un proyecto en curso que promete ofrecer soluciones precisas y valiosas para problemas de predicción de series temporales considerando factores económicos.

REFERENCES

- [1] A. Agrawal, J. Gans, and A. Goldfarb, "Economic policy for artificial intelligence," *Innovation Policy and the Economy*, vol. 19, no. 1, pp. 139-159, 2019. Agrawal, A., Gans, J., & Goldfarb, A. *Power and prediction: The disruptive economics of artificial intelligence*. Harvard Business Review Press, 2022.
- [2] A. Abadie, S. Athey, G. W. Imbens, y J. M. Wooldridge, "When should you adjust standard errors for clustering?" *The Quarterly Journal of Economics*, vol. 138, no. 1, pp. 1-35, 2023.
- [3] S. Athey, "The impact of machine learning on economics," en *The Economics of Artificial Intelligence: An Agenda*, University of Chicago Press, 2018, pp. 507-547.
- [4] H. R. Varian, "A Bayesian approach to real estate assessment," en *Studies in Bayesian Econometrics and Statistics in Honor of Leonard J. Savage*, 1975.
- [5] H. R. Varian, "Microeconomía intermedia: un enfoque actual". Alpha Editorial, 2016.
- [6] R. Bommasani, D. A. Hudson, E. Adeli, R. Altman, S. Arora, S. von Arx, et al., "On the opportunities and risks of foundation models," *arXiv preprint arXiv:2108.07258*, 2021.
- [7] E. Brynjolfsson, D. Li, and L. R. Raymond, "Generative AI at work," *National Bureau of Economic Research, Tech. Rep.*, 2023.
- [8] E. Brynjolfsson, W. Jin, y K. McElheran, "The power of prediction: predictive analytics, workplace complements, and business performance," *Business Economics*, vol. 56, pp. 217-239, 2021.
- [9] A. Agrawal, J. Gans, y A. Goldfarb, "Prediction machines: the simple economics of artificial intelligence," *Harvard Business Press*, 2018.
- [10] C. Catalini y J. S. Gans, "Some simple economics of the blockchain," *Communications of the ACM*, vol. 63, no. 7, pp. 80-90, 2020.

- [11] D. Acemoğlu, D. Autor, J. Hazell, P. Restrepo, E. Calvano, G. Calzolari, et al., "Dangers of unregulated artificial intelligence," *VoxEU.org*, vol. 23, 2021.
- [12] D. Siddarth, D. Acemoglu, D. Allen, K. Crawford, J. Evans, M. Jordan, y E. Weyl, "How AI fails us," *arXiv preprint arXiv:2201.04200*, 2021.
- [13] R. M. Devens, "Cyclopædia of Commercial and Business Anecdotes: Comprising Interesting Reminiscences and Facts, Remarkable Traits and Humors, and Notable Sayings Dealings, Experiences, and Witticisms of Merchants, Traders, Bankers, Mercantile Celebrities, Millionaires, Bargain Makers, etc., etc. in All Ages and Countries," 1865.
- [14] D. Keith. "Una breve historia de la inteligencia empresarial." [En línea]. Disponible en: <https://www.dataversity.net/brief-history-business-intelligence/>. [Fecha de acceso: Agosto 29, 2023].
- [15] J.L. Cano. "Business Intelligence: Competir con Información". ESADE. 2007.
- [16] U. M. R. Alcocer, E. Tello-Leal, y A. B. R. Alvarado, "Modelo basado en redes neuronales recurrentes LSTM para la predicción de la siguiente actividad en procesos de negocio," *Pistas Educativas*, vol. 40, no. 130, 2018.
- [17] J. J. D. L. Fernández, "Estimación adelantada del crecimiento regional mediante redes neuronales LSTM," *Investigaciones Regionales=Journal of Regional Research*, no. 49, pp. 45-64, 2021.
- [18] J. A. Guamán Pachacama y G. B. Segura Muñoz, "Red neuronal Long Short-Term Memory (LSTM) aplicada a series temporales para pronosticar consumo energético en edificaciones," Bachelor's thesis, Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Físicas, Carrera de Ingeniería en Sistemas Computacionales, 2021
- [19] M. C. A. B. Vilchis, "Business Intelligence como estrategia para optimización de flujos de efectivo ante entornos emergentes," *Estrategias Organizacionales*, vol. 63.
- [20] F. Hamad, R. Al-Aamr, S. A. Jabbar, y H. Fakhuri, "Business intelligence in academic libraries in Jordan: Opportunities and challenges," *IFLA Journal*, vol. 47, no. 1, pp. 37-50, 2021.
- [21] A. M. García Pérez, "Aplicación de técnicas de inteligencia de negocios y análisis de datos en el entorno empresarial cubano: retos y perspectivas," en **Revista Cubana de Ciencias Informáticas**, vol. 14, no. 4, pp. 191-209, 2020.
- [22] Banxico. (2023, Agosto 29). Sistema de Información Económica. [En línea]. Disponible en: <https://www.banxico.org.mx/SieInternet/consultarDirectorioInternetAction.do?sector=8&accion=consultarCuadro&idCuadro=CP154&locale=es>. [Fecha de acceso: Agosto 29, 2023].
- [23] M. Valdéz. (2023, Agosto 30). El Proceso de Business Intelligence. [En línea]. Disponible en: <https://www.rtm.com.pe/articulos-destacados/el-proceso-de-bi/>. [Fecha de acceso: Agosto 30, 2023].
- [24] N. Hidalgo Jordán, "Modelización de datos económicos utilizando series temporales."
- [25] D. Beteta García, "Modelización de datos económicos utilizando series temporales," 2020.