

UNIVERSIDAD DE CÓRDOBA

Programa de Doctorado en
Computación Avanzada, Energía y Plasmas
Departamento de Informática y Análisis Numérico



Predicción de indicadores económicos en
Ecuador mediante técnicas de
programación genética

Predicting economic indicators in Ecuador using
genetic programming techniques

MEMORIA DE TESIS PRESENTADA POR

Kevin Mero Ramírez

DIRECTORES

Dr. Sebastián Ventura Soto

Dr. Jaime Meza Hormaza

Córdoba, Febrero de 2025

TITULO: *PREDICCIÓN DE INDICADORES ECONÓMICOS EN
ECUADOR MEDIANTE TÉCNICAS DE PROGRAMACIÓN GENÉTICA*

AUTOR: *Kevin Mero Ramírez*

© Edita: UCOPress. 2025
Campus de Rabanales
Ctra. Nacional IV, Km. 396 A
14071 Córdoba

[https://www.uco.es/ucopress/index.php/es/
ucopress@uco.es](https://www.uco.es/ucopress/index.php/es/ucopress@uco.es)



TÍTULO DE LA TESIS: Predicción de indicadores económicos en Ecuador mediante técnicas de programación genética

DOCTORANDO/A: Kevin Mero Ramírez

INFORME RAZONADO DEL/DE LOS DIRECTOR/ES DE LA TESIS

(se hará mención a la evolución y desarrollo de la tesis, así como a trabajos y publicaciones derivados de la misma).

En la tesis doctoral se ha realizado un estudio detallado del estado del arte en lo referente a predicción de indicadores económicos mediante IA y técnicas de programación genética. Dicho estudio ha permitido publicar un artículo de revisión en una revista de renombre en la comunidad científica (*Proceedings of the 6th International Conference on Engineering & MIS 2020*) de la editorial Association for Computing Machinery (ACM). Con este análisis del estado del arte, se diseñó un algoritmo híbrido multidimensional GA-LSTM, cuyo objetivo es la predicción de la tasa de desempleo en Ecuador para facilitar la toma de decisiones estratégicas. Esta herramienta ha permitido detectar patrones complejos y fluctuantes característico de la tasa de desempleo ecuatoriana y predecir con mayor precisión ese índice respecto a modelos tradicionales RNN del tipo BiLSTM y GRU. El trabajo fue propuesto para un número especial en la revista de alto impacto Applied Sciences, mismo que fue publicado en el año 2024.

Con todo lo anterior, los directores de esta tesis doctoral consideran que el informe de la presente tesis doctoral es muy favorable.

Por todo ello, se autoriza la presentación de la tesis doctoral.

Córdoba, 21 de Febrero de 2025

Firma del/de los director/es

Fdo.: Sebastián Ventura Soto

Fdo.: Jaime Meza Hormaza

La memoria titulada "*Predicción de indicadores económicos en Ecuador mediante técnicas de programación genética*", que presenta Kevin Michael Mero Ramírez para optar al grado de Doctor, ha sido realizada dentro del programa de doctorado "*Computación avanzada, energía y plasmas*" del Departamento de Informática y Análisis Numérico de la Universidad de Córdoba, bajo la dirección de los doctores Sebastián Ventura Soto y Jaime Meza Hormaza cumpliendo, en su opinión, los requisitos exigidos a este tipo de trabajos.

Córdoba, Febrero de 2025

El Doctorando

Fdo.: Kevin Mero Ramírez

El Director

El Director

Fdo.: Dr. Sebastián Ventura Soto

Fdo.: Dr. Jaime Meza Hormaza

“El verdadero viaje de descubrimiento no consiste en buscar nuevos paisajes sino en tener nuevos ojos”.

--Marcel Proust

Agradecimientos

No quisiera dejar pasar la oportunidad de expresar mi más sincero agradecimiento a todas las personas que, de manera directa o indirecta, hicieron posible la realización de esta tesis doctoral.

En primer lugar, extiendo mi especial reconocimiento a mis directores de tesis, los profesores Dr. Sebastián Ventura Soto y Dr. Jaime Meza Hormaza, por su invaluable orientación, apoyo y paciencia a lo largo de este proceso. También agradezco al Dr. Luis Chamba Eras y a la Dra. Diana Pacheco, personas expertas externas de esta tesis, por sus valiosas observaciones y sugerencias que enriquecieron el trabajo.

Deseo expresar mi gratitud al profesor Dr. José Luna, a quien conocí en el Departamento de Informática y Análisis Numérico de la Universidad de Córdoba, por sus valiosos conocimientos y apoyo durante las etapas iniciales de la investigación.

Extiendo un agradecimiento especial a mi familia. A mi esposa Kelly Bazante y a mis hijas, Mayra, Glenda y Sofia, quienes me brindaron fuerzas y apoyo incondicional en los momentos en que tuvimos que sacrificar tiempo juntos para que yo pudiera culminar este importante estudio. A mi padre Glenn Mero († 2012) y madre Magaly Ramírez por su amor y cariño incondicional; así como, a mi abuelita Shirley Sánchez († 2016) quien con sus sabios consejos me inculcó la responsabilidad y el trabajo.

Finalmente, deseo expresar un agradecimiento a la Universidad Técnica de Manabí, institución en la que me formé académicamente y que me proporcionó las oportunidades y recursos necesarios para llevar a cabo y culminar mis estudios doctorales.

Resumen

En la presente tesis doctoral se desarrolla un modelo predictivo avanzado para estimar la tasa de desempleo en Ecuador aplicando técnicas de Inteligencia Artificial (IA) y Computación Evolutiva (CE). La predicción de la tasa de desempleo es fundamental ya que ayuda a los tomadores de decisiones públicas a formular políticas y a planificar la economía de un país basados en datos, aquello les permite anticipar condiciones y tomar decisiones informadas. Por lo tanto, el modelo propuesto ofrece una alternativa innovadora que integra un Algoritmo Genético y Memoria a Largo y Corto Plazo (GA-LSTM) que ayude a mejorar la precisión de las predicciones considerando las complejidades de los datos económicos ecuatorianos

Es bien conocido que muchos modelos estadísticos tradicionales dependen del supuesto de normalidad, en donde los datos a analizar siguen una distribución normal; a diferencia, el enfoque híbrido propuesto maneja adecuadamente la naturaleza no lineal, estacional y no estacionaria de los datos de desempleo. En este modelo híbrido las redes Memoria a Largo y Corto Plazo (LSTM) se combinan con Algoritmo Genético (GA) permitiendo ajustar los hiperparámetros de tamaño de la ventana y unidades ocultas LSTM del modelo que permita capturar los patrones temporales y secuenciales de la serie de datos.

A diferencia de otros modelos predictivos que se basan en suposiciones de normalidad de los datos, el enfoque propuesto maneja adecuadamente la naturaleza no lineal, estacional y no estacionaria de los datos de desempleo. Las redes Memoria a Largo y Corto Plazo (LSTM), conocidas por su capacidad para capturar patrones temporales y secuenciales, son optimizadas en esta investigación mediante un Algoritmo Genético (GA), lo que permite ajustar los hiperparámetros del modelo, como el tamaño de la ventana de tiempo y la cantidad de unidades LSTM, maximizando así la precisión en la predicción.

La metodología empleada incluyó las etapas de recolección y preprocesamiento de datos económicos, el Análisis Exploratorio de Datos (EDA), la construcción de un modelo híbrido GA-LSTM y de los modelos referenciales, y por último la evaluación de la precisión de predicción de los modelos desarrollados. La ejecución cuidadosa de la metodología permitió que el modelo híbrido capture las tendencias y las fluctuaciones de la tasa de desempleo ecuatoriana. Se emplearon las técnicas de comparación entre los modelos utilizando las métricas MSE, MAE y MAPE y la prueba estadística t pareada para evaluar el desempeño.

Se utilizaron técnicas de comparación en los distintos modelos para analizar el desempeño de GA-LSTM en comparación con los tipos de Redes Neuronales Recurrentes (RNNs), Memoria a Largo y Corto Plazo Bidireccional (BiLSTM) y la Unidad Recurrente Cerrada (GRU); adicionalmente se usó la prueba estadística t-pareada para validar la efectividad de los modelos.

Los resultados experimentales muestran que el modelo híbrido GA-LSTM es más preciso que los modelos BiLSTM y GRU en la estimación de la tasa de desempleo en Ecuador. Esta mejora destaca lo efectivos que son los modelos combinados para el análisis y predicción de datos complejos y cambiantes, ofreciendo una herramienta para predecir tendencias de desempleo en Ecuador.

El aporte es un nuevo enfoque en la predicción económica usando métodos inteligentes como la IA y la CE. Además de predecir el desempleo, el nuevo modelo tiene potencia para poderse aplicar a otros indicadores económicos, convirtiéndose en una herramienta clave para los encargados de tomar decisiones estratégicas gubernamentales en Ecuador.

Palabras clave: Predicción económica, Redes Neuronales LSTM, Algoritmos Genéticos, Ecuador, Tasa de Desempleo.

Abstract

In this doctoral thesis, an advanced predictive model is developed to estimate the unemployment rate in Ecuador by applying Artificial Intelligence (AI) and Evolutionary Computation (EC) techniques. Unemployment rate prediction is essential as it helps public decision makers formulate policies and plan a country's economy based on data, allowing them to anticipate conditions and make informed decisions. Therefore, the proposed model offers an innovative alternative that integrates a Genetic Algorithm and Long-Short-Term Memory (GA-LSTM) that helps improve the accuracy of predictions considering the complexities of Ecuadorian economic data.

It is well known that many traditional statistical models rely on the assumption of normality, where the data to be analyzed follows a normal distribution; in contrast, the proposed hybrid approach adequately handles the non-linear, seasonal and non-stationary nature of unemployment data. In this hybrid model, Long Short-Term Memory (LSTM) networks are combined with Genetic Algorithm (GA) allowing to tune the hyperparameters of window size and LSTM hidden units of the model to capture the temporal and sequential patterns of the data series.

Unlike other predictive models that rely on assumptions of data normality, the proposed approach adequately handles the non-linear, seasonal and non-stationary nature of unemployment data. Long Short-Term Memory (LSTM) networks, known for their ability to capture temporal and sequential patterns, are optimized in this research using a Genetic Algorithm (GA), which allows fine-tuning the model hyperparameters, such as the time window size and the number of LSTM units, thus maximizing prediction accuracy.

The methodology used included the stages of economic data collection and preprocessing, Exploratory Data Analysis (EDA), the construction of a hybrid GA-LSTM model and the reference models, and finally the evaluation of the prediction accuracy of the developed models. The careful execution of the methodology allowed the hybrid model to capture the trends and fluctuations of the Ecuadorian unemployment rate. The comparison techniques between the models using the MSE, MAE and MAPE metrics and the paired t statistical test were used to evaluate the performance.

Comparison techniques were used in the different models to analyze the performance of GA-LSTM in comparison with the types of Recurrent Neural Networks (RNNs), Bidirectional Long Short-Term

Memory (BiLSTM) and Gated Recurrent Unit (GRU); additionally, the paired t-test was used to validate the effectiveness of the models.

The experimental results show that the hybrid GA-LSTM model is more accurate than the BiLSTM and GRU models in estimating the unemployment rate in Ecuador. This improvement highlights how effective the combined models are for the analysis and prediction of complex and changing data, offering a tool to predict unemployment trends in Ecuador.

The contribution is a new approach to economic prediction using intelligent methods such as AI and CE. In addition to predicting unemployment, the new model has the power to be applied to other economic indicators, becoming a key tool for those responsible for making strategic government decisions in Ecuador.

Keywords: Economic prediction, LSTM neural networks, Genetic algorithms, Ecuador, Unemployment rate.

Índice de Contenidos

Índice de Figuras	XIX
Índice de Tablas.....	XX
Lista de Acrónimos.....	XXI
1. INTRODUCCIÓN	1
1.1. Motivación	1
1.2. Objetivos	2
1.3. Proceso de la tesis doctoral	3
1.4. Contexto de la investigación.....	4
1.5. Estructura	4
2. MARCO TEÓRICO	6
2.1. Predicción	6
2.2. Indicadores económicos	13
2.2.1. La tasa de desempleo	15
2.3. Fuentes de datos	24
2.4. Aprendizaje automático para el análisis predictivo de datos	26
2.4.1. Introducción al aprendizaje automático para el análisis predictivo de datos	26
2.4.2. La tabla base analítica y la exploración de datos	29
2.5. La predicción de indicadores económicos	30
2.6. Algoritmos de IC aplicados en la predicción de la tasa de desempleo	37
2.6.1. Red neuronal artificial (ANN)	38
2.6.2. Red neuronal recurrente (RNN)	39
2.6.2.1. Memoria a largo y corto plazo (LSTM)	40
2.6.2.2. Memoria a largo y corto plazo bidireccional (BiLSTM)	42
2.6.2.3. Unidades recurrentes cerradas (GRU).....	42
2.6.3. Algoritmos genéticos	43
2.6.4. Modelo híbrido GA-LSTM.....	45
3. METODOLOGÍA.....	48
3.1. Planteamiento del problema	48
3.2. Solución propuesta y esquema metodológico.....	49
3.2.1. Recopilación y preprocesamiento de los datos.....	51

3.2.2. Análisis Exploratorio de los Datos (EDA)	56
3.2.2.1. Integridad de los datos	56
3.2.2.2. Características de la distribución de los datos	57
3.2.2.3. Análisis de correlación	61
3.2.3. Modelado y evaluación	62
3.2.3.1. Aplicación del algoritmo híbrido GA-LSTM.....	64
3.3. Comparación de enfoques.....	73
4. EXPERIMENTACIÓN.....	74
4.1. Fase experimental	74
4.1.1. Configuración del entorno de desarrollo	74
4.1.2. Proceso de entrenamiento y prueba	76
4.1.3. Evaluación del desempeño	78
4.2. Resumen de la fase experimental	79
4.3. Resultados	80
4.4. Discusión	84
5. CONCLUSIONES Y TRABAJOS FUTUROS.....	86
5.1. Conclusiones.....	86
5.2. Trabajos futuros	87
5.3. Difusión de resultados.....	88
Bibliografía.....	90
Apéndices	102
Apéndice A. Estudios para la predicción del PIB	102
Apéndice B. Estudios para la predicción de la tasa de desempleo.....	119
Apéndice C. Estudios para la predicción del IPC	124
Apéndice D. Estudios para la predicción de la tasa de cambio	130
Apéndice E. Estudios para la predicción de la inflación	152
Apéndice F. Factores predictores que influyen en la tasa de desempleo	162

Índice de Figuras

Figura 2.1. Tipos de predicciones.....	6
Figura 2.2. Evolución de la tasa de desempleo en Ecuador, enero 2002 - febrero 2019	17
Figura 2.3. Distribución de la tasa de desempleo en Ecuador, enero 2002 - febrero 2019	18
Figura 2.4. Código en R de la prueba RESET de Ramsey	20
Figura 2.5. Descomposición aditiva simple con estacionalidad constante (figura de la izquierda) y Descomposición aditiva con estacionalidad variable (figura de la derecha).....	22
Figura 2.6. Código en R para la descomposición de la serie temporal de la tasa de desempleo	23
Figura 2.7. Código en R para la prueba de ADF de la tasa de desempleo	24
Figura 2.8. Subajuste, Equilibrado y sobreajuste [48].....	29
Figura 2.9. Redes neuronales biológicas (A, C) y artificiales (B, D) [88]	39
Figura 2.10. RNN enrollada y desenrollada.....	40
Figura 2.11. Esquema general de una red neuronal LSTM para x_t . Se puede observar la interacción entre los módulos LSTM y los tipos de puertas que componen un módulo LSTM.....	41
Figura 2.12. La arquitectura desplegada de BiLSTM con tres pasos consecutivos [106].....	42
Figura 2.13. La estructura de la celda de memoria de la unidad recurrente cerrada [109]	43
Figura 2.14. Modelo GA-LSTM para la predicción de la tasa de desempleo	47
Figura 2.15. Fases y etapas del proceso de predicción de la tasa de desempleo	49
Figura 2.16. Relación jerárquica general entre la solución de análisis, dominios/subdominios y características descriptivas para predecir la tasa de desempleo	55
Figura 2.17. Gráficos de violín de las variables	57
Figura 2.18. Histograma de distribución de diferentes variables.....	58
Figura 2.19. Código en R para determinar el Coeficiente de Asimetría de diferentes variables	59
Figura 2.20 Mapa de calor de la tasa de desempleo vs. inflación, salario mínimo, PIB y FBCF	62

Índice de Tablas

Tabla 2.1. Estadísticos descriptivos de la tasa de desempleo en Ecuador	16
Tabla 2.2. Pruebas de normalidad de la tasa de desempleo en Ecuador	17
Tabla 2.3. Modelos que no dependen de supuestos de normalidad	19
Tabla 2.4. Prueba RESET de Ramsey para el desempleo.....	20
Tabla 2.5. Prueba de ADF para el desempleo	24
Tabla 2.6. Modelos de IA utilizados en la predicción de indicadores económicos.....	36
Tabla 2.7. Variables dependientes e independientes utilizadas	52
Tabla 2.8. Determinación de valores atípicos en las características descriptivas	53
Tabla 2.9. Conjunto de datos de desempleo en Ecuador (2002-2019)	53
Tabla 2.10. Rango de variables	54
Tabla 2.11. Prueba de Dickey-Fuller de diferentes variables	57
Tabla 2.12. Características estadísticas de los datos.....	58
Tabla 2.13. Coeficiente de Asimetría para diferentes variables.....	59
Tabla 2.14. Variables significativas	61
Tabla 2.15. Parámetros del modelo GA	67
Tabla 2.16. Parámetros óptimos del modelo LSTM	67
Tabla 2.17. Configuración técnica del modelo GA-LSTM	68
Tabla 2.18. Algoritmo híbrido GA-LSTM	72
Tabla 2.19. Distribución de muestras para la regresión de la tasa de desempleo según el modelo utilizado.....	76
Tabla 2.20. La medida del desempeño de los modelos para predecir la tasa de desempleo	80
Tabla 2.21. Resultados prueba t	81
Tabla 2.22. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de BiLSTM 1L	82
Tabla 2.23. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de BiLSTM 2L	82
Tabla 2.24. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de GRU 1L	83
Tabla 2.25. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de GRU 2L	83
Tabla 2.26. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de GA-LSTM 1L	83
Tabla 2.27. Resultados de correlaciones pareadas entre las tasas de desempleo reales y puntuaciones de los modelos de predicción.....	84

Lista de Acrónimos

- ABT:** Analytical Base Table (Tabla Base Analítica)
- ADF:** Augmented Dickey–Fuller (Dickey-Fuller Aumentada)
- ANN:** Artificial Neural Network (Red Neuronal Artificial)
- ANN-PSO:** Artificial Neural Network and Particle Swarm Optimization (Red Neuronal Artificial y Optimización por Enjambre de Partículas)
- ANNs:** Artificial Neural Networks (Redes Neuronales Artificiales)
- ARIMA:** Autoregressive Integrated Moving Average (Autorregresivo Integrado de Media Móvil)
- ARIMA-ANN:** Autoregressive Integrated Moving Average and Artificial Neural Network (Autorregresivo Integrado de Media Móvil y Red Neuronal Artificial)
- ARIMA-ARNN:** Autoregressive Integrated Moving Average and Autoregressive Neural Network (Autorregresivo Integrado de Media Móvil y Red Neuronal Autorregresiva)
- ARIMA-BP:** Autoregressive Integrated Moving Average and Backpropagation (Autorregresivo Integrado de Media Móvil y Retropropagación)
- ARIMA-SVM:** Autoregressive Integrated Moving Average and Support Vector Machine (Autorregresivo Integrado de Media Móvil y Máquinas de Vectores de Soporte)
- ARMA:** Autoregressive Moving Average (Autorregresivo de Media Móvil)
- ARMA-GARCH:** Autoregressive Moving Average and Generalized Autoregressive Conditional Heteroskedasticity (Autorregresivo de Media Móvil y Heterocedasticidad Condicional Autorregresiva Generalizada)
- ARNN:** Autoregressive Neural Network (Red Neuronal Autorregresiva)
- BCE:** Banco Central del Ecuador
- BEA:** Bureau of Economic Analysis (Oficina de Análisis Económico)
- BiLSTM:** Bidirectional Long Short-Term Memory (Memoria a Largo y Corto Plazo Bidireccional)
- BLS:** Bureau of Labor Statistics (Oficina de Estadísticas Laborales)
- BMA-PAR:** Bayesian Model Averaging y Periodic Autoregressive (Promedio Bayesiano de Modelos y Autorregresivo Periódico)
- BP:** Backpropagation (Retropropagación)
- BPAP:** Bayesian Periodic Autoregressive (Autorregresivo Periódico Bayesiano)
- BPNN:** Back Propagation Neural Network (Redes Neuronales de Retropropagación)
- CB:** Conference Board (Junta de Conferencias)
- CE:** Evolutionary Computation (Computación Evolutiva)
- CNN:** Convolutional Neural Network (Red Neuronal Convolutiva)
- CNN-TLSTM:** Convolutional Neural Network and Tanh Long Short-Term Memory (Red Neuronal Convolutiva y Memoria a Largo y Corto Plazo con Tangente Hiperbólica)
- CRISP-DM:** Cross-Industry Standard Process for Data Mining (Proceso Estándar Intersectorial para la Minería de Datos)
- CX:** Customer Experience (Experiencia del Cliente)
- DBN:** Deep Belief Network (Red de Creencias Profundas)
- DBN-LSTM:** Deep Belief Network and Long Short-Term Memory (Red de Creencias Profundas y Memoria a Largo y Corto Plazo)
- DOC:** Department of Commerce (Departamento de Comercio)
- DT:** Decision Tree (Árbol de Decisión)
- EA:** Evolutionary Algorithms (Algoritmos Evolutivos)
- EDA:** Exploratory Data Analysis (Análisis Exploratorio de Datos)
- ELM:** Extreme Machine Learning (Máquina de Aprendizaje Extremo)

- ELM-ABC:** Extreme Machine Learning and Artificial Bee Colony (Máquina de Aprendizaje Extremo y Colonia de Abejas Artificiales)
- EMD-LSTM-SVR:** Empirical Mode Decomposition, Long Short-Term Memory y Support Vector Regression (Descomposición Empírica de Modos, Memoria a Largo y Corto Plazo y Regresión de Vectores de Soporte)
- FAR:** Functional Autoregressive (Autorregresivo Funcional)
- FARIMA:** Fractionally Integrated Autoregressive Moving Average (Autorregresivo Integrado de Media Móvil Fraccionario)
- FBCF:** Formación Bruta de Capital Fijo
- Fed:** Federal Reserve (Reserva Federal)
- FMI:** Fondo Monetario Internacional
- FOMC:** Federal Open Market Committee (Comité Federal de Mercado Abierto)
- GA:** Genetic Algorithm (Algoritmo Genético), Genetic Algorithm (Algoritmo Genético)
- GA-LSTM:** Genetic Algorithm and Long and Short-Term Memory (Algoritmo Genético y Memoria a Largo y Corto Plazo)
- GARCH:** Generalized Autoregressive Conditional Heteroscedasticity (Heterocedasticidad Condicional Autorregresiva Generalizada)
- GARCH-MIDAS:** Generalized Autoregressive Conditional Heteroscedasticity with Mixed-Data Sampling (Heterocedasticidad Condicional Autorregresiva Generalizada con Muestreo de Datos Mixtos)
- GA:** Genetic algorithms (Algoritmos Genéticos)
- GP:** Genetic Programming (Programación Genética)
- GRU:** Gated Recurrent Unit (Unidad Recurrente Cerrada)
- GRU-RNN:** Gated Recurrent Unit and Recurrent Neural Network (Unidad Recurrente Cerrada y Red Neuronal Recurrente)
- I+D:** Investigación y Desarrollo
- IA:** Inteligencia Artificial
- IC:** Computational Intelligence (Inteligencia Computacional)
- INE:** Instituto Nacional de Estadística
- INEC:** Instituto Nacional de Estadística y Censos
- INEGI:** Instituto Nacional de Estadística y Geografía
- IPC:** Índice de Precios al Consumidor
- IPCA:** Índice Nacional de Precios al Consumidor Amplio
- IPP:** Índice de Precios al Productor
- K-S:** Kolmogorov-Smirnov
- LASSO-BiLSTM:** Least Absolute Shrinkage and Selection Operator - Bidirectional Long Short-Term Memory (Operador de Selección y Contracción Mínima Absoluta - Memoria a Largo y Corto Plazo Bidireccional)
- LightGBM:** Light Gradient Boosting Machine (Máquinas Potenciadas por Gradiente Ligero)
- LoLiMoT:** Local Linear Model Tree (Árbol de Modelos Lineales Locales)
- LSTM:** Long Short-Term Memory (Memoria a Largo y Corto Plazo), Long Short-Term Memory (Memoria a Largo y Corto Plazo)
- LSTM-GRU:** Long Short-Term Memory and Gated Recurrent Unit (Memoria a Largo y Corto Plazo y Unidades Recurrentes Cerradas)
- LSTM-PSO:** Long Short-Term Memory with Particle Swarm Optimization (Memoria a Largo y Corto Plazo con Optimización por Enjambre de Partículas)
- ML:** Machine Learning (Aprendizaje Automático), Machine Learning (Aprendizaje Automático)

- MLP:** Multilayer Perceptron (Perceptrón Multicapa)
- NARX-NN:** Nonlinear Autoregressive Exogenous Neural Network (Red Neuronal Autorregresiva No Lineal con Exógenos)
- NFCI:** National Financial Conditions Index (Índice Nacional de Condiciones Financieras)
- NNAR:** Neural Network Autoregressive (Red Neuronal Autorregresiva)
- NNTFGM:** Neural Network Triangular Fuzzy-Number Grey Model (Modelo Gris de Números Difusos Triangulares con Redes Neuronales)
- OECD:** Organisation for Economic Co-operation and Development (Organización para la Cooperación y el Desarrollo Económicos)
- PCE:** Personal Consumption Expenditures (Gastos de Consumo Personal)
- PIB:** Producto Interno Bruto
- PMEANS:** Periodic Means (Medias Periódicas)
- RF:** Random Forest (Bosque Aleatorio)
- RMB:** Renminbi
- RNN:** Recurrent Neural Network (Red Neuronal Recurrente)
- RNNs:** Recurrent Neural Networks (Redes Neuronales Recurrentes)
- SARIMA:** Seasonal Autoregressive Integrated Moving Average (Autorregresivo Integrado de Media Móvil Estacional)
- SARMA:** Spatial Autoregressive Moving Average (Autorregresivo de Media Móvil Espacial)
- SVM:** Support Vector Machine (Máquina de Vectores de Soporte)
- SVR:** Support Vector Regression (Regresión de Vectores de Soporte)
- tanh:** Tangente Hiperbólica
- TCN:** Temporal Convolutional Network (Red Convolutiva Temporal)
- UE:** Unión Europea
- USD:** United States Dollar (Dólar Estadounidense)
- USD/CNY:** United States Dollar to Chinese Yuan (Dólar Estadounidense a Yuan Chino)
- USTPU:** United States Trade Policy Uncertainty Index (Índice de Incertidumbre en la Política Comercial de Estados Unidos)
- VaR:** Value at Risk (Valor en Riesgo)
- VMD-CEEMDAN-GRU-ATCN:** Variational Mode Decomposition, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, Gated Recurrent Unit and Attention-Based Temporal Convolutional Network (Descomposición Modal Variacional, Descomposición Completa Empírica de Modos con Ruido Adaptativo, Unidad Recurrente Cerrada y Red Convolutiva Temporal Basada en Atención)
- WA-LSTM:** Wavelet Analysis and Long Short-Term Memory (Análisis Wavelet y Memoria a Largo y Corto Plazo)
- XGBoost:** Extreme Gradient Boosting (Impulso de Gradiente Extremo)

INTRODUCCIÓN

En este apartado se describe los aspectos centrales y relevancia del trabajo. Se describe la motivación que impulsa este trabajo, destacando la importancia de predecir indicadores económicos clave para la toma de decisiones estratégicas en el contexto ecuatoriano. Se presenta el objetivo general y los objetivos específicos propuestos que guían el desarrollo de la investigación. Posteriormente se detalla el proceso de trabajo seguido a lo largo de la tesis doctoral, describiendo las etapas metodológicas y las fases claves. En la sección 1.4 se explora el contexto en el que se desarrolló la investigación, enfatizando los retos económicos relevantes para el estudio. Finalmente, la sección 1.5 describe la estructura y organización de la tesis, orientando al lector sobre el contenido de los capítulos posteriores.

1.1. Motivación

La capacidad de predecir con precisión indicadores económicos clave es fundamental para la estabilidad y el desarrollo de cualquier país. En un entorno económico caracterizado por la alta volatilidad y la dependencia de factores externos, la predicción precisa de indicadores económicos como la tasa de desempleo, el Producto Interno Bruto (PIB), el Índice de Precios al Consumidor (IPC), la tasa de cambio y la inflación, se vuelve crucial para tomar decisiones informadas en varios ámbitos como el gubernamental, financiero, organizacional y social. Debido a la vulnerabilidad del contexto económico a los cambios en los mercados globales, la necesidad de adaptarse a los cambios sociales y demográficos, la búsqueda de eficiencia y transparencia en la administración pública y la reducción de las disparidades para mejorar la calidad de vida; resulta o se hace cada vez más apremiante la necesidad de políticas que se basen y fundamenten en datos verificables y actuales. La implementación de políticas informadas permite a los gobiernos responder de manera oportuna, eficiente y eficaz a los desafíos económicos y sociales actuales que atraviesa un país.

En Ecuador un enfoque predictivo robusto que mejore la planificación económica y permita respuestas oportunas contribuye a la formulación de estrategias orientadas a impulsar el crecimiento económico y a la mitigación del impacto de factores externos como las fluctuaciones en

los precios del petróleo, las variaciones en las tasas de interés globales y las condiciones del comercio internacional.

Aunque los métodos tradicionales de análisis económico son útiles, presentan limitaciones para capturar la complejidad de los datos económicos actuales, los cuales suelen ser no lineales, heterogéneos y con componentes de alta dimensionalidad. En este contexto, los modelos de IA se presentan como alternativas que permiten abordar estos desafíos con mayor precisión. Técnicas avanzadas como las RNNs y los GA ofrecen un marco prometedor para modelar patrones temporales complejos y no lineales en datos económicos. La combinación de estos métodos en un modelo híbrido puede mejorar la precisión en la predicción de la tasa de desempleo en Ecuador, contribuyendo para que los responsables de la toma de decisiones analicen y mitiguen los efectos económicos de las fluctuaciones en el mercado laboral.

La necesidad de contar con una herramienta predictiva sofisticada que aborde las características únicas de la economía ecuatoriana es el objeto de estudio. La implementación de un modelo híbrido GA-LSTM permite superar los inconvenientes de los modelos unidimensionales, como el manejo de datos no estacionarios y la captura de patrones de dependencia temporal a lo largo de series de tiempo. Esto permite una formulación de políticas más precisa basadas en una data con variaciones económicas. Adicionalmente, este estudio pretende establecer un marco metodológico que pueda replicarse en otros estudios similares en contextos económicos similares, además de proponer un avance técnico.

Al mejorar la precisión de las predicciones aplicando la optimización de hiperparámetros, se contribuye a una planificación económica más efectiva, lo que fortalece el análisis de políticas laborales y la gestión de recursos públicos. Aplicando un enfoque innovador basado en LSTM y GA, esta investigación busca contribuir a una toma de decisiones informada que promueva el desarrollo económico, la estabilidad laboral y la eficiencia en la formulación de políticas.

1.2. Objetivos

Desarrollar un modelo predictivo avanzado que permita predecir la tasa de desempleo aplicando técnicas de programación genética que contribuya a una toma de decisiones informada en políticas económicas y planificación nacional.

Los objetivos específicos son:

- Clasificar los métodos de inteligencia artificial empleados en la predicción de los principales indicadores económicos como el PIB, la tasa de desempleo y la inflación para lo cual se realizará una revisión exhaustiva de la literatura.
- Desarrollar un modelo híbrido de predicción para lo cual se va a combinar redes neuronales recurrentes LSTM con GA.
- Determinar los hiperparámetros del modelo predictivo de la tasa de desempleo utilizando GA, para ello se va a optimizar el tamaño de la ventana de tiempo y el número de unidades ocultas LSTM.
- Comparar el rendimiento del modelo GA-LSTM vs. los modelos individuales de redes neuronales BiLSTM y GRU, usando las métricas de evaluación MSE, MA y MAPE; así como, el procedimiento estadístico prueba t-pareada.

1.3. Proceso de la tesis doctoral

Para el desarrollo de esta tesis doctoral se utilizó un enfoque metódico y minucioso que abarcó varias fases importantes. Se inició con la realización de una revisión exhaustiva de la literatura científica identificando los últimos enfoques o modelos de predicción de inteligencia artificial, aprendizaje automático, aprendizaje profundo y programación genética, de los principales indicadores económicos, con énfasis en la predicción de la tasa de desempleo. Esta fase permitió establecer una base teórica sólida y definir los objetivos de investigación que guiaron esta tesis. A continuación, se recolectaron y preprocesaron los datos económicos de fuentes oficiales, lo que supone un paso fundamental para garantizar la calidad y representatividad de los datos utilizados. Se utilizaron técnicas avanzadas de análisis exploratorio de datos (EDA) para identificar patrones, tendencias y posibles problemas de calidad en los datos, como valores faltantes o atípicos.

El desarrollo metodológico se centró en la implementación de un modelo híbrido que combina redes de memoria de largo y corto plazo (LSTM) optimizadas mediante algoritmos genéticos (GA). Esta etapa implicó configurar los parámetros del modelo, seleccionar las métricas de evaluación adecuadas y validar su eficacia mediante experimentos comparativos con otros enfoques predictivos de redes neuronales recurrentes.

Finalmente, en base a los resultados analizados se elaboraron conclusiones que permitieron abordar los objetivos de la investigación y aportar una perspectiva innovadora sobre el uso de técnicas híbridas en el análisis de datos económicos de tasas de desempleo. Esta metodología fue iterativa, lo que permitió ajustes y mejoras continuas hasta lograr un modelo robusto y preciso.

1.4. Contexto de la investigación

La presente tesis doctoral se desarrolla en un contexto económico caracterizado por la alta volatilidad y la creciente necesidad de herramientas predictivas avanzadas que apoyen la toma de decisiones estratégicas. En Ecuador, los indicadores económicos, como la tasa de desempleo, han mostrado un comportamiento complejo, influenciado por factores externos como las fluctuaciones en los precios del petróleo y las condiciones del comercio internacional, así como por factores internos relacionados con políticas económicas y sociales. En este entorno, las técnicas tradicionales de análisis económico presentan limitaciones para capturar las dinámicas no lineales y la estacionalidad inherente a los datos económicos. Este desafío ha impulsado la necesidad de explorar métodos innovadores, como las redes neuronales y los algoritmos genéticos, que ofrecen una mayor capacidad para modelar patrones temporales complejos.

El contexto también está definido por un creciente interés en la aplicación de la inteligencia artificial y la computación evolutiva mediante la aplicación de Algoritmos Evolutivos (EA) y algoritmos de enjambres en problemas económicos. Estos enfoques permiten superar las limitaciones de los modelos tradicionales y ofrecen una oportunidad para desarrollar herramientas más precisas y adaptativas que apoyen la formulación de políticas públicas y la planificación económica en países en desarrollo como Ecuador. Esta investigación busca contribuir a este campo emergente, integrando técnicas avanzadas de predicción en un modelo híbrido GA-LSTM que responde a las necesidades específicas del contexto ecuatoriano, con el potencial de ser replicado en otros escenarios económicos similares.

1.5. Estructura

Esta sección actúa como una guía para facilitar a los lectores la búsqueda del contenido de esta tesis y la comprensión de ciertos aspectos de su estructura.

El Capítulo 1 presenta las bases teóricas de los principales indicadores económicos y su predicción a través de IA. Este capítulo trata los conceptos económicos más importantes, examina la tasa de desempleo a través de indicadores estadísticos y una revisión de los métodos de IA utilizados en la predicción de los indicadores económicos más relevantes; este capítulo establece el fundamento teórico para la implementación de estos métodos en entornos económicos.

El Capítulo 2 detalla la metodología utilizada en esta tesis. Se detalla el método utilizado, que abarca la recolección y el preprocesamiento de datos, el EDA y la creación del modelo predictivo híbrido que fusiona redes neuronales recurrentes LSTM con GA.

El Capítulo 3 especifica los experimentos llevados a cabo para confirmar el modelo sugerido. Este capítulo abarca la configuración del ambiente experimental, el procedimiento de entrenamiento y evaluación del modelo, además de un análisis de los resultados. Además, se contrasta el rendimiento del modelo vs. otros métodos de redes neuronales recurrentes individuales, valorando su exactitud y eficacia en la proyección del índice de desempleo en el contexto ecuatoriano.

El Capítulo 4 expone las conclusiones derivadas de la investigación y propone posibles investigaciones futuras. Se reflexionan los hallazgos y el efecto de la metodología utilizada en la exactitud de las proyecciones económicas de la tasa de desempleo, además se proponen mejoras y rutas de investigación que pueden ser exploradas con la finalidad de mejorar el rendimiento del modelo y su aplicación en otros contextos económicos.

MARCO TEÓRICO

En esta sección se ofrecen los fundamentos teóricos requeridos para situar los indicadores económicos y su estimación a través de técnicas de IA. Se detallan los indicadores económicos más relevantes propuestos por investigadores, economistas y expertos, enfocándose en la investigación de la tasa de desempleo y el análisis de su comportamiento histórico en el escenario ecuatoriano. Además, se ofrece un escenario exhaustivo acerca de los métodos de IA y GA utilizados en la predicción económica del índice de la tasa de desempleo, resaltando los beneficios y limitaciones de estos métodos en comparación con los métodos convencionales de RNN. Este marco teórico actúa como base para la metodología y el modelo híbrido planteado.

2.1. Predicción

La predicción es una estimación sobre un evento futuro utilizando los patrones de datos históricos de una serie temporal a los que se les aplican modelos estadísticos, de aprendizaje automático o híbridos. Se basa en la idea de que los patrones y las tendencias observadas en el pasado pueden utilizarse para predecir el comportamiento o los resultados en el futuro. Esto concuerda con los autores [1], [2], [3] quienes afirman que la predicción implica estimar valores futuros en una serie de datos a partir de sus valores históricos. Además, destacan que el análisis predictivo emplea diferentes algoritmos estadísticos y técnicas de aprendizaje automático aplicados a datos históricos para anticipar resultados futuros. Esta capacidad de prever el futuro es fundamental para la toma de decisiones informadas y estratégicas en numerosos ámbitos. La predicción es un área de interés en varios campos de estudio, como la economía, la ciencia política, ciencias sociales, la psicología, entre otras. Los tipos de predicción son: predicción para el pasado (hindcasting), predicción para el presente (nowcasting) y predicción para el futuro (forecasting) (Figura 2.1.).




Figura 2.1. Tipos de predicciones

Las palabras predecir y pronosticar se utilizan como sinónimos, implican anticipar eventos o condiciones futuras, pero predecir puede tener un enfoque más amplio que involucra observación, experiencia o razón científica, mientras que pronosticar a menudo se asocia más específicamente con el análisis de datos en el contexto meteorológico. Según los diccionarios "Merriam-Webster" y "The American Heritage", mencionan:

- **Predecir:** Declarar, indicar o dar a conocer de antemano. Predecir sobre la base de la observación, la experiencia o la razón científica [4]. Predecir es anunciar sobre la base de conocimientos especiales. Ejemplo: predijo una temporada activa de huracanes debido a las temperaturas más cálidas de la superficie del océano [5].
- **Pronosticar:** Predecir algo futuro a partir de indicios. Calcular o predecir algún evento o condición futura generalmente como resultado del estudio y análisis de los datos pertinentes. Indica que es probable que ocurra. Ejemplos: La empresa prevé unos beneficios reducidos, los optimistas pronostican un repunte inmediato del negocio [6]. Estimar o predecir con anticipación, especialmente predecir condiciones climáticas mediante el análisis de datos meteorológicos. Usada para presagiar eventos o condiciones venideras. Ejemplo: aumentos de precios que pronostican inflación [7].

Brown [8] menciona que la predicción es un arte, basado en la hábil ponderación subjetiva de una gran cantidad de factores. Estos factores se pueden medirse de manera explícita como las tendencias pasadas o los patrones estacionales en los datos, o medirse cuantitativamente como el impacto en el mercado de un nuevo producto, los cambios de precio o una nueva campaña promocional. Las aplicaciones de análisis de datos predictivos incluyen, pero no se limitan a los siguientes campos:

- **Empresa,** la predicción permite tomar a los jefes empresariales decisiones estratégicas, financieras y operativas. Las organizaciones recopilan datos históricos como ventas, comportamiento de los clientes y tendencias del mercado que les permita realizar pronósticos sobre las demandas futuras y a su vez ajustar sus operaciones. Ejemplos:
 - **Ventas:** Una predicción eficaz de las ventas en el comercio electrónico ayudaría a los minoristas a elaborar planes precisos de control de producción. Los gobiernos e instituciones gubernamentales utilizan y de inventario, lo que a su vez les ayudaría a reducir los costos de inventario y las pérdidas vencidas [9].
 - **Demanda:** Las empresas pueden prever la demanda de productos específicos basándose en datos históricos de ventas, eventos promocionales, tendencias estacionales y cambios en el comportamiento del consumidor; lo que le permite

ajustar su inventario y planificar adecuadamente la producción para satisfacer la demanda anticipada. Pronosticar la demanda de nuevos productos representa un desafío, un enfoque innovador para aquello es el método DemandForest [10].

- **Precios:** Las empresas pueden utilizar modelos predictivos para anticipar cambios en los precios de los productos o servicios. Los precios de los productos son influenciados por factores externos como la oferta y la demanda, condiciones económicas, fluctuaciones en los costos de producción, desastres naturales que aumenta el precio de productos agrícolas [11], entre otros.
- **Clientes:** Utilizando datos sobre el comportamiento del cliente, interacciones pasadas y comentarios, las empresas pueden prever la probabilidad de retención de clientes. Este tipo de predicción ayuda a las empresas a desarrollar estrategias efectivas de gestión de clientes para la retención de clientes existentes para obtener la máxima ventaja en el mercado [12].
- **Política**, en el ámbito político, la predicción se emplea para entender y anticipar el impacto de las políticas gubernamentales en la sociedad, economía y medio ambiente [13], [14]. Los gobiernos utilizan modelos de predicción para permitirles tomar decisiones informadas sobre políticas públicas considerando su impacto en el empleo, la distribución de la riqueza, la equidad social y otros aspectos clave de la vida de los ciudadanos. Ejemplo:
 - **Políticas gubernamentales:** La predicción del impacto de diferentes políticas en la economía implica considerar una variedad de factores como cambios en impuestos, programas de estímulo económico y regulaciones comerciales.
- **Medicina**, la predicción es fundamental en el diagnóstico temprano y el tratamiento de enfermedades. Los modelos predictivos ayudan a los médicos a evaluar el riesgo de enfermedades y predecir la aparición o progresión de una enfermedad. Ejemplos:
 - **Enfermedades cardiovasculares:** Los modelos predictivos pueden evaluar factores como la presión arterial, el colesterol, la edad y el historial familiar para prever el riesgo de enfermedades cardiovasculares [15]. Esto permite a los médicos implementar intervenciones preventivas y recomendar cambios en el estilo de vida del paciente para reducir el riesgo.
 - **Cáncer:** El pronóstico del cáncer consiste en estimar el destino del cáncer, las probabilidades de recurrencia y progresión del cáncer, y proporcionar una estimación de la supervivencia a los pacientes [16]. Estos modelos ayudan a que los

- oncólogos adapten los planes de tratamiento de acuerdo con la información clínica y la biología relacionada con la enfermedad, proporcionando de esta manera estimaciones más exactas sobre el futuro de la enfermedad y la expectativa de vida de los pacientes.
- **Enfermedades genéticas:** Utilizando datos genéticos y técnicas de modelado, los modelos predictivos pueden ayudar a identificar el riesgo de enfermedades genéticas hereditarias. Algunos estudios se han enfocado en comprender la base genética de condiciones como el Alzheimer y otras enfermedades complejas (diabetes mellitus tipo 2, arterias coronarias, cáncer de mama, entre otras) [17], [18]. Estos enfoques están permitiendo un mejor entendimiento de la etiología genética de estas enfermedades, su prevención y tratamiento personalizado.
 - **Brotos epidémicos:** Los modelos epidemiológicos predicen la propagación de enfermedades infecciosas para ello toman en cuenta los factores biológicos, del ambiente y sociales.
 - **Enfermedades neurodegenerativas:** Los modelos predictivos permiten evaluar la progresión de enfermedades como el Alzheimer o el Parkinson para ayudar a los médicos a planificar intervenciones y tratamientos que permitan mejorar la calidad de vida de los pacientes.
 - **Complicaciones obstétricas:** En obstetricia, los modelos predictivos pueden evaluar el riesgo de complicaciones durante el embarazo, parto o posparto [19], [20], [21]. Esto ayuda a los profesionales de la salud a tomar decisiones informadas sobre la atención prenatal y el manejo del parto y posparto.
- En términos **económicos**, la predicción es esencial para la estrategia de planificación y la toma de decisiones en el ámbito empresarial y financiero. Los analistas y economistas emplean modelos de IA y econométricos y otros métodos de series temporal para anticipar la conducta de los mercados financieros, la inflación, el desempleo, el PIB y otros indicadores económicos esenciales. Estas estimaciones son esenciales para el diseño de políticas económicas y la administración de inversiones. Ejemplos:
 - **PIB:** El PIB es la principal característica del crecimiento económico. La predicción precisa del PIB de las regiones en desarrollo puede proporcionar apoyo técnico para el desarrollo urbano sostenible y la formulación de políticas económicas [22]. Los analistas económicos utilizan modelos econométricos para prever el crecimiento del

PIB de un país. Estas predicciones son fundamentales para la formulación de políticas gubernamentales, la toma de decisiones empresariales y la evaluación del bienestar económico general. Algunos factores que se usan para predecir el PIB son científicos y tecnológicos como el gasto en investigación y desarrollo (I+D), artículos en revistas científicas y técnicas, solicitudes de patentes de no residentes y residentes, solicitudes de marcas de no residentes y residentes, solicitudes totales de marcas, investigadores en I+D, técnicos en I+D y exportaciones de alta tecnología [23].

- **Inflación:** Los economistas emplean diversos modelos para prever la inflación, analizando un amplio conjunto de variables como los índices de precios, las tasas de interés, las condiciones del mercado laboral, indicadores del mercado financiero, la actividad económica y factores internacionales [24]. Estos métodos pueden clasificarse en modelos de series temporales, modelos estructurales, modelos de precios de activos y métodos basados en encuestas [25]. Las predicciones de inflación son fundamentales para la planificación de políticas monetarias y fiscales.
- **Desempleo:** Los economistas, investigadores y profesionales utilizan modelos para prever las tasas de desempleo, considerando factores macroeconómicos como el PIB, tasa de inflación, salario mínimo, Formación Bruta de Capital Fijo (FBCF), importaciones y exportaciones totales, gastos financieros, entre otros. Así mismo, se usan otros tipos de factores que influyen en el desempleo como variables laborales, de búsqueda en línea, sociales, demográficas, financieras y de mercado. Estas predicciones son fundamentales para diseñar estrategias de empleo y formular políticas laborales.
- **Tipo de cambio:** Los analistas económicos utilizan modelos para prever el movimiento de las tasas de cambio entre diferentes monedas. Esto es crucial para las empresas que operan en mercados internacionales, así como para los inversores que gestionan carteras de divisas.
- La **meteorología** para pronosticar el clima a corto y largo plazo. Los meteorólogos modelos atmosféricos y técnicas de IA que utilizan datos históricos para predecir eventos dentro de patrones climáticos tales como tormentas, huracanes y cambios estacionales. Estas predicciones permiten tomar medidas de precaución y planificar actividades en función de las condiciones climáticas esperadas. Ejemplos:

- **Clima:** Los meteorólogos utilizan modelos atmosféricos basados en datos históricos y técnicas de inteligencia artificial para prever las condiciones climáticas diarias y estacionales a corto y largo plazo. Esto incluye pronósticos de temperatura y precipitaciones estacionales [26], [27], [28].
- **Eventos meteorológicos:** Considerando el análisis de datos climáticos y los patrones atmosféricos se pueden prever eventos meteorológicos extremos como lluvia y niebla [29], permitiendo a las autoridades tomar medidas preventivas para reducir los riesgos a la población.
- El análisis de datos predictivos en el sector **bancario** juega un papel esencial en la administración de riesgos y la toma de decisiones financieras. Las entidades financieras emplean modelos predictivos para estimar la posibilidad de impagos en los créditos, detectar fraudes y optimizar la personalización de los servicios financieros. Además, la anticipación de tendencias del mercado y la conducta del consumidor asiste a las instituciones financieras a mejorar la distribución de recursos y a ajustar sus tácticas de productos y servicios brindados a sus clientes. Ejemplos:
 - **Evaluación de riesgo de crédito:** Las instituciones financieras utilizan modelos predictivos para calcular la probabilidad de impago de un cliente antes de otorgarle un préstamo. Este análisis se basa en el historial crediticio del cliente, datos financieros y patrones de comportamiento [30], [31].
 - **Detección de fraude:** Los bancos aplican técnicas de predicción y algoritmos de aprendizaje automático para identificar transacciones sospechosas en tiempo real, reduciendo así los riesgos de fraude financiero [32], [33].
 - **Satisfacción del cliente:** Mediante el análisis predictivo de factores clave de la Experiencia del Cliente (CX), las instituciones financieras pueden anticipar y mejorar la satisfacción, priorizando inversiones en áreas críticas como conveniencia, credibilidad y competencia del personal. Este enfoque permite ganar y retener clientes en mercados competitivos, optimizando la experiencia y fomentando la lealtad [34], [35].
- En el campo de la **inteligencia artificial**, el uso de predicciones es crucial para varias áreas, tales como el procesamiento del lenguaje natural, la visión computacional y la toma de decisiones autónomas. Los modelos de IA emplean métodos sofisticados de aprendizaje automático para realizar predicciones en tiempo real y adaptaciones a patrones emergentes

ajustando su comportamiento conforme a nuevas tendencias o cambios del entorno. Esto es relevante en asistentes virtuales, reconocimiento facial, sistemas de recomendaciones, vehículos autónomos y una serie de aplicaciones que intentan imitar o replicar la inteligencia humana con el fin de optimizar la eficiencia y la toma de decisiones en tiempo real. Ejemplos:

- **Asistentes virtuales:** Los modelos predictivos en IA permiten a asistentes virtuales como Siri o Alexa anticipar las necesidades de los usuarios basándose en interacciones previas y patrones de uso. Según el estudio realizado por [36], la interacción con asistentes virtuales comerciales se caracteriza por la atribución de rasgos humanos, lo que conduce a los usuarios a describir estos sistemas de forma antropomórfica. Esto sugiere que los usuarios no solo emplean estos asistentes para tareas prácticas, sino que también les asignan roles sociales y esperan que en el futuro adopten cualidades aún más humanas.
- **Reconocimiento facial:** La visión por computadora utiliza predicciones para identificar rostros en tiempo real, mejorando la seguridad y permitiendo aplicaciones como el desbloqueo facial en dispositivos móviles. La tecnología de reconocimiento facial ha avanzado significativamente con la incorporación de redes neuronales profundas, las cuales mejoran la precisión y robustez frente a condiciones no controladas, como cambios en iluminación y ángulo de la cámara, factores críticos en aplicaciones móviles y de seguridad [37]. Además, el uso de modelos ligeros de Red Neuronal Convolucional (CNN) permiten la implementación en dispositivos móviles, preservando la privacidad del usuario y optimizando la velocidad de procesamiento, como se demuestra en aplicaciones de afecto facial en tiempo real [38].
- **Sistemas de recomendación:** Plataformas de streaming y comercio electrónico utilizan algoritmos predictivos para sugerir contenido o productos que el usuario podría preferir, basándose en su historial de navegación y preferencias pasadas.

Aunque la predicción ofrece grandes oportunidades, también presenta desafíos y limitaciones. La incertidumbre inherente a la predicción, junto con la calidad y disponibilidad de los datos, puede afectar la precisión de las predicciones. Además, las predicciones futuras están influenciadas por factores y eventos inesperados, lo que resalta la importancia de un enfoque cauteloso y la evaluación constante de los modelos predictivos.

Es importante tener en cuenta que la predicción no garantiza resultados precisos y definitivos, ya que está sujeta a diversas incertidumbres y limitaciones. Sin embargo, con enfoques rigurosos y el uso adecuado de datos relevantes, la predicción puede proporcionar información valiosa y contribuir a la comprensión y la planificación de eventos futuros.

2.2. Indicadores económicos

Los indicadores económicos son medidas o estadísticas sobre una actividad económica. Se utilizan para evaluar y analizar la salud general de una economía. Estos indicadores proporcionan información clave sobre diversos aspectos de la actividad económica, como el crecimiento, la inflación, el desempleo, el comercio internacional, entre otros. Los indicadores económicos influyen directamente en las decisiones estratégicas de las empresas públicas y privadas y, en este contexto, resulta fundamental evaluar los datos, en un intento de predecir el comportamiento futuro de dichas cifras [39].

Algunos indicadores comunes son:

- **PIB:** El PIB es el valor total de todos los bienes y servicios producidos en un país durante un período específico. Es uno de los indicadores más importantes para medir el crecimiento económico. Un PIB en aumento indica una economía en expansión, mientras que un PIB en declive puede señalar una recesión.
- **PIB per cápita:** Es una métrica que desglosa el PIB de un país en términos de asignación por persona. Es el resultado de dividir el PIB de un país por su población. Este indicador es útil para determinar la prosperidad de los países en función de su crecimiento económico. Además, se ha empleado para modelar los resultados de salud, las tendencias de mortalidad, la estimación de la mortalidad por causas específicas, el desempeño y las finanzas del sistema de salud y varios otros temas de interés [40].
- **Tasa de desempleo:** Este indicador muestra el porcentaje de la fuerza laboral que está desempleada y busca activamente empleo. Una tasa de desempleo alta puede señalar una economía en problemas mientras que una tasa baja comúnmente se vincula con un sólido crecimiento económico.
- **IPC:** El IPC es un índice que mide la variación promedio a lo largo del tiempo de los precios que pagan los consumidores de un grupo específico de productos y servicios. Este conjunto de bienes y servicios se conoce como "*cesta de la compra*" e incluye alimentos, vivienda, transporte, salud, entre otros. El IPC es crucial ya que mide la inflación que experimentan y

perciben los consumidores en sus gastos cotidianos. El IPC representa los cambios en los precios de todos los bienes y servicios adquiridos para el consumo de los hogares urbanos y mide la inflación que experimentan los consumidores en sus gastos diarios de vida [41]. Los gobiernos y las empresas utilizan el IPC para formular políticas económicas, ajustar los contratos y calcular aumentos de salarios y pensiones.

- **Salario mínimo:** El salario mínimo es el salario o remuneración más baja que los empleadores puede pagar legalmente a sus empleados por hora o mes de trabajo. El propósito principal del salario mínimo es salvaguardar a los empleados de salarios bajos asegurando que obtengan una remuneración justa por su labor. El establecimiento del salario mínimo es responsabilidad del gobierno y puede variar significativamente entre países y regiones. Frecuentemente, el salario mínimo se ajusta de manera periódica para reflejar variaciones en el costo de vida y conservar el poder de compra de los empleados en un nivel mínimo aceptable. Las discusiones acerca del sueldo mínimo generalmente se enfocan en su efecto en el empleo, la pobreza, la inflación y la competitividad económica.
- **Inflación:** La inflación mide el incremento general de los costos de bienes y servicios en una economía durante un periodo de tiempo específico. Un grado moderado de inflación puede ser beneficioso para una economía, dado que puede señalar un crecimiento. Sin embargo, una inflación desmedida puede erosionar el poder adquisitivo de la moneda y provocar inestabilidad económica.

Los indicadores económicos se clasifican en indicadores adelantados, rezagados y coincidentes.

- **Adelantados:** Son indicadores que normalmente, aunque no siempre, cambian antes de que cambie la economía en su conjunto. Ejemplos: el Índice de Precios al Productor (IPP), el índice de pedidos de bienes duraderos, índice de expectativas de los consumidores, permisos de construcción, condiciones crediticias, las acciones, entre otros.
- **Rezagados:** Son indicadores que generalmente cambian después de que lo hace la economía en su conjunto. Ejemplos: IPC, índice de precios de los Gastos de Consumo Personal (PCE), tasa de desempleo, gastos del consumidor, entre otros.
- **Coincidentes:** Son indicadores que cambian aproximadamente al mismo tiempo que toda la economía, proporcionando así información sobre el estado actual de la economía. Ejemplos: PIB, la producción industrial, los ingresos personales y las ventas minoristas.

2.2.1. La tasa de desempleo

La tasa de desempleo es un indicador clave de la situación del mercado laboral en una economía. Calcula el porcentaje de la población activa que busca empleo, pero no puede encontrarlo. Su cálculo se realiza dividiendo el número de personas desempleadas entre la población activa total, y generalmente aumenta durante las recesiones comerciales y disminuye durante las expansiones comerciales [42]. Este indicador es crucial para comprender la salud económica de un país o región, ya que incide tanto en la dinámica de la producción y el consumo nacional como en la estabilidad financiera de los hogares.

Una tasa de desempleo baja refleja un indicador positivo, ya que indica que la mayoría de las personas que desean trabajar se encuentran empleadas. Esto puede indicar una economía estable o en crecimiento. Sin embargo, las tasas extremadamente bajas también pueden ser problemáticas porque se presenta el fenómeno de mercado laboral demasiado ajustado que conlleva a generar presiones inflacionarias. Una de las consecuencias de este fenómeno es la competencia por trabajadores escasos, en donde las empresas que compiten por mano de obra escasa pueden experimentar un fuerte aumento o alza de los salarios lo cual eleva los costos operativos empresariales y en última instancia la subida de los precios de los productos y servicios al consumidor, lo que puede generar inflación. Además, una tasa de desempleo baja puede no reflejar siempre el panorama completo, ya que algunas personas pueden haber abandonado la fuerza laboral y, por lo tanto, no están incluidas en las estadísticas.

Por otra parte, una tasa de desempleo elevada es frecuentemente un signo de dificultades económicas. Puede haber un número significativo de personas sin empleo, lo que podría indicar una desaceleración económica o un estancamiento en algunos sectores productivos. Esto podría afectar negativamente al bienestar familiar, reducir el consumo y obstaculizar el crecimiento económico. Además, si el desempleo elevado persiste en el tiempo, puede tener efectos negativos a largo plazo, como la pérdida de habilidades entre los trabajadores despedidos o cambios estructurales en la economía, aumentando aún más la dificultad para su reinserción en el mercado laboral. En consecuencia, las tasas de desempleo altas o bajas tienen implicaciones significativas para las políticas públicas, el crecimiento económico y el bienestar social, lo que hace que su análisis sea esencial para la toma de decisiones tanto gubernamentales como empresariales.

Para entender los ciclos económicos es fundamental analizar la tasa de desempleo. Durante las recesiones más personas pierden sus empleos porque las empresas reducen sus operaciones, por el

contrario, en los periodos de expansión la economía crece y se crean más oportunidades de empleo. No todas las formas de desempleo son iguales: el desempleo estructural ocurre cuando las habilidades de los empleados no coinciden o se alinean con lo que buscan los empleadores, mientras que el desempleo friccional es un componente natural de los trabajadores debido a que por diversas razones cambian de empleos o se dan un tiempo de espera antes de empezar en un nuevo puesto.

Es importante realizar un análisis detallado para separar los factores estacionales y comprender la tendencia real del desempleo. El análisis de la estabilidad económica permite ajustar la tasa de desempleo considerando fluctuaciones regulares, como las que ocurren en sectores como la agricultura o el comercio durante ciertas temporadas de vacaciones, festividades o determinados tiempos de cosechas de productos vegetales. Este componente es clave ya que determinados modelos estadísticos de series temporales como SARIMA o de suavizado exponencial de Holt-Winters permiten ajustar y aislar dicho efecto.

Antes de pronosticar el proceso, se realiza un análisis descriptivo de los datos variables de la tasa de desempleo, proporcionados por el Instituto Nacional de Estadística y Censos (INEC)¹ del Ecuador para obtener descripciones e información exploratoria.

La Tabla 2.1. muestra los valores mínimo, máximo, promedio, cuartil 1, mediana y cuartil 3 para la variable de tasa de desempleo en Ecuador. La tasa de desempleo más baja es de 4.54 y la más alta de 11.50. La tasa de desempleo promedio es de 6.8495.

Estadísticos descriptivos de la tasa de desempleo en Ecuador						
Variable	Mínimo	Q1	Mediana	Media	Q3	Máximo
Tasa de desempleo	4.54	5.4850	6.6800	6.8495	7.8900	11.50

Tabla 2.1. Estadísticos descriptivos de la tasa de desempleo en Ecuador

En la Figura 2.2. se representa los datos de la tasa de desempleo de enero de 2002 a diciembre de 2019, con un total de 216 muestras. La tendencia es variable a lo largo del tiempo, entre 2002 al 2003 el empleo aumentó y alcanzó un pico de 11.50% en enero de 2003. Luego, la tasa comenzó a disminuir constantemente hasta el 2007, alcanzando un valle de 6.07% en diciembre. Desde ese punto, la tasa comenzó a disminuir de manera constante hasta 2007, reduciéndose el desempleo a 6.07% en diciembre. Sin embargo, durante la crisis financiera mundial del 2008 al 2009, la tasa de desempleo aumentó, alcanzando un valor máximo de 9,06% en septiembre de 2009. Además, se

¹ <https://www.ecuadorencifras.gob.ec/>

analiza, que del 2010 al 2014 la economía se recuperó y el desempleo volvió a descender, alcanzando su nivel más bajo de 4.54% en diciembre 2014 muy probablemente debido a las políticas internas de estabilidad y recuperación económica impulsadas por el gobierno de turno. Finalmente, entre 2015 al 2017, la tasa de desempleo alcanza su máximo valor de 7.35% en marzo de 2016, debido a la caída de los precios del petróleo y otros factores económicos; y entre 2017 a 2019 la tasa disminuye cerrando el período con un 4.95% en diciembre de 2019.




Figura 2.2. Evolución de la tasa de desempleo en Ecuador, enero 2002 - febrero 2019

La tasa de desempleo en Ecuador ha mostrado tendencias cíclicas, con períodos de crecimiento y de caída influenciados por crisis globales, fluctuaciones en los precios del petróleo y factores internos. Si bien las fluctuaciones en el desempleo reflejan la vulnerabilidad del país a factores externos, la economía ecuatoriana ha demostrado capacidad para recuperarse después de la crisis.

La Tabla 2.2. muestra que el valor de significancia de la prueba Kolmogorov-Smirnov (K-S) es 0, lo que indica que los datos no siguen una distribución normal. En la prueba K-S, se utiliza un nivel de significancia de 0.05 como punto de corte para decidir si se rechaza o acepta la hipótesis nula.

Kolmogorov-Smirnov			
Variable	Estadístico	gl	Sig.
Tasa de desempleo	0.125	216	0.000

Tabla 2.2. Pruebas de normalidad de la tasa de desempleo en Ecuador

La Figura 2.3. representa la distribución de la tasa de desempleo en Ecuador entre enero de 2002 y febrero de 2019. En la figura se observa las variaciones en los niveles de desempleo a lo largo del

tiempo, destacando tanto los valores máximos como mínimos alcanzados durante el período de estudio. En la distribución se facilita la identificación de los patrones generales, incluyendo períodos caracterizados por incrementos significativos en la tasa de desempleo, estabilidad o reducción en los niveles de desempleo. El análisis detallado de esta distribución resulta fundamental para comprender la dinámica del mercado laboral ecuatoriano y analizar el impacto de factores internos y externos que pudieron incidir en las fluctuaciones observadas en la tasa de desempleo a lo largo de los años evaluados.




Figura 2.3. Distribución de la tasa de desempleo en Ecuador, enero 2002 - febrero 2019

La no normalidad de la tasa de desempleo ecuatoriana puede tener implicaciones económicas significativas, ya que refleja características estructurales o fundamentales de la economía que no son regulares ni predecibles. En el contexto económico, la no normalidad puede estar vinculada a factores estructurales, coyunturales o de política económica. Esto conlleva a utilizar modelos que no se basen en supuestos de normalidad, como modelos de regresión robusta, modelos estadísticos y modelos de aprendizaje automático, para predecir datos que no siguen una distribución normal (Tabla 2.3.). Estos enfoques permiten captar mejor las características y fluctuaciones de datos complejos como los de las tasas de desempleo.

Modelos que no dependen de supuestos de normalidad		
Regresión robusta	Estadísticos	Aprendizaje automático
- Modelo de regresión cuantílica ² .	- <i>Modelos autorregresivos</i> ³ : Autorregresivo Integrado de Media Móvil (ARIMA), Autorregresivo Integrado de Media Móvil Estacional (SARIMA), Heterocedasticidad Condicional Autorregresiva Generalizada (GARCH).	- Árbol de Decisión (DT) y Bosque Aleatorio (RF). - Máquina de Vectores de Soporte (SVM). - <i>Redes Neuronales</i> : ANNs y RNNs (LSTM, BiLSTM y GRU). - K-vecinos más Cercanos (KNN) - Redes Bayesianas

Tabla 2.3. Modelos que no dependen de supuestos de normalidad

Las redes RNNs se utilizan a menudo para realizar predicciones en situaciones en las que los datos tienen patrones complejos y no siguen una distribución normal. Una de sus principales ventajas es que no requieren suposiciones de normalidad porque los modelos LSTM, BiLSTM y GRU están diseñados para capturar dependencias temporales o secuenciales en los datos sin suponer que estos siguen una distribución particular. Además, estos modelos son particularmente eficaces para identificar relaciones no lineales y complejas a lo largo del tiempo, resulta conveniente su uso para predecir el desempleo y otros índices, donde los datos son secuenciales y no siempre siguen un patrón regular o predecible.

Prueba de linealidad

La prueba de linealidad se utilizó para verificar la correcta especificación del modelo en cuanto a la relación entre la variable dependiente (Y) y las variables explicativas (X). Si los datos no cumplen con el supuesto de linealidad, es recomendable recurrir a modelos no lineales, como redes neuronales, árboles de decisión o modelos basados en series temporales (ARIMA, SARIMA o GARCH). Estas técnicas estadísticas y matemáticas son ideales para capturar y predecir relaciones no lineales

² La regresión cuantil no se basa en los supuestos de normalidad o errores homocedásticos para modelar los percentiles condicionales [43].

³ Los modelos tradicionales de series temporales, como ARMA, ARIMA y SARIMA, se desarrollaron bajo el supuesto de que la varianza es constante o varía estacionalmente. En cambio, el modelo GARCH es adecuado para modelar series temporales con varianza condicional heterocedástica, es decir, cuando la varianza fluctúa en el tiempo y no permanece constante [44]. Por lo tanto, dado que ARIMA y SARIMA se enfocan en la estacionariedad y constancia de la varianza, mientras que GARCH se aplica cuando la varianza es inconstante, estos modelos no requieren estrictamente que los datos sigan una distribución normal, ya que ese no es su enfoque principal. Los modelos autorregresivos ARIMA, SARIMA y GARCH funcionan mejor cuando los residuos (errores entre los valores observados y predichos) se aproximan a la normalidad, aunque no es un requisito estricto.

entre las variables de entrada y la variable objetivo. Por lo tanto, se realizará una prueba de linealidad con la estadística de prueba RESET de Ramsey con el siguiente proceso [45]:

Hipótesis:

- *Hipótesis nula* $H_0: a_1 = a_2 = \dots = a_k = 0$ (No existe ninguna especificación errónea en el modelo o el modelo es lineal).
- *Hipótesis alternativa* $H_1: a_k \neq 0$ Al menos un signo igual no es válido (Existe una especificación incorrecta en el modelo o el modelo es no lineal).

Estadísticas de la prueba: Prueba RESET de Ramsey

$$RESET = \frac{[(\hat{e}'\hat{e} - \hat{u}'\hat{u})/p^*]}{[(\hat{u}'\hat{u})/(n - k)]} \quad (1)$$

Según la Tabla 2.4. se concluye que dado que el valor p es menor que α , se rechaza H_0 , lo que significa que el modelo no es lineal.

Prueba RESET de Ramsey	
RESET	p-valor
31.464	1.134×10^{-12}

Tabla 2.4. Prueba RESET de Ramsey para el desempleo

Criterios de prueba: **Rechazar H_0** si el valor $p \leq \alpha$, en otros casos, se acepta. Dado que el valor $p = 1.134 \times 10^{-12} < \alpha = 0.05$, entonces se rechaza la hipótesis nula H_0 .

La Figura 2.4. muestra el código desarrollado en R para realizar la prueba RESET de Ramsey.

```
# Instalar y cargar el paquete lmtest
install.packages("lmtest")
library(lmtest)
# Leer el dataset desempleo.csv
datos <- read.csv("C:/desempleo.csv", header = TRUE, sep = ";")
head(datos)
str(datos)
# Ajustar el modelo de regresión lineal
modelo <- lm(desempleo ~ Salario + PIB + Inflacion + FBCF, data = datos)
summary(modelo)
# Realizar la prueba general RESET de Ramsey
resultado_reset <- resettest(modelo)
print(resultado_reset)
# Probar términos cuadráticos y cúbicos
resettest(modelo, power = 2)
resettest(modelo, power = 3)
```

Figura 2.4. Código en R de la prueba RESET de Ramsey

Prueba de estacionalidad y estacionariedad

La **estacionalidad** se refiere a los patrones repetitivos o cíclicos que ocurren en una serie temporal en intervalos regulares, generalmente debido a factores como estaciones del año, cambios climáticos, vacaciones o eventos recurrentes. Estos patrones se repiten en intervalos fijos, como cada mes, trimestre o año, y suelen estar relacionados con fenómenos externos predecibles. Ejemplo de patrones estacionales: el aumento de las ventas en diciembre debido a la temporada navideña, el aumento en el desempleo cada invierno, entre otros. La estacionalidad se puede detectar visualmente al observar una serie temporal o mediante técnicas de descomposición de series temporales. También se puede medir mediante la autocorrelación en los datos a intervalos específicos. Por otra parte, la **estacionariedad** se refiere a la constancia de las propiedades estadísticas (media, varianza, autocorrelación) de una serie temporal. Si una serie es estacionaria, no tiene una tendencia a largo plazo ni varía significativamente en su comportamiento estadístico con el tiempo.

Ambos conceptos son fundamentales para elegir el modelo adecuado para analizar una serie temporal. ARIMA, por ejemplo, requiere que la serie sea estacionaria, mientras que, si hay estacionalidad, se puede optar por modelos como SARIMA para capturar esos patrones repetitivos.

A continuación, se muestra el análisis de la estacionalidad de la tasa de desempleo en Ecuador, usando la descomposición aditiva simple con estacionalidad constante y la descomposición aditiva con estacionalidad variable a lo largo del tiempo, utilizando suavizado local (Figura 2.5.).

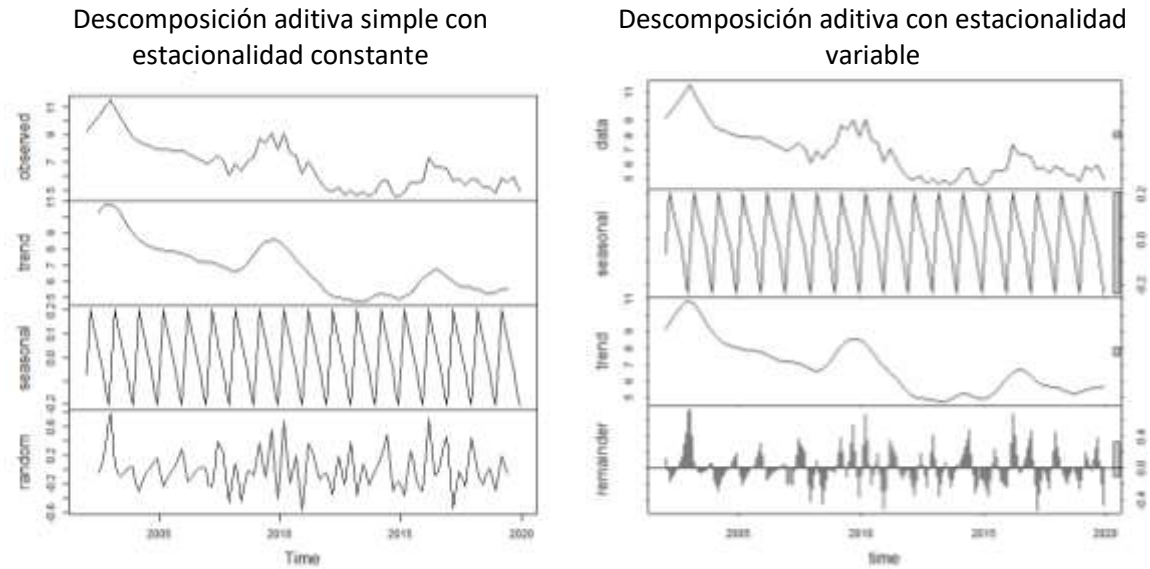


Figura 2.5. Descomposición aditiva simple con estacionalidad constante (figura de la izquierda) y Descomposición aditiva con estacionalidad variable (figura de la derecha)

El análisis de la descomposición de la tasa de desempleo revela que este indicador está influenciado por tres componentes principales. La **tendencia a largo plazo (trend)** muestra una disminución significativa del desempleo desde 2002 hasta aproximadamente 2010, seguida por una estabilización con ligeras fluctuaciones hasta 2019. Este comportamiento sugiere un período inicial de mejora en el mercado laboral seguido de una fase de estabilización. El **componente estacional** refleja tendencias que se repiten consistentemente cada año, lo que indica la presencia de fluctuaciones predecibles durante épocas específicas del año. Es probable que estas diferencias se deban a factores como los ciclos económicos, la demanda estacional de mano de obra en sectores como el turismo, la agricultura o el comercio; así como, a políticas gubernamentales que tienen un efecto cíclico sobre el empleo. Por último, los **residuos o fluctuaciones aleatorias (random/remainder)** muestran algunos picos en ciertos momentos, que pueden estar relacionados con eventos inesperados o factores externos (cambios en las políticas laborales, crisis económicas, circunstancias no recurrentes, entre otras). Estos picos no son muy pronunciados muestran variaciones que no son capturados por la tendencia o la estacionalidad, reflejando indicios de influencias externas sobre la serie de desempleo.

La Figura 2.6. muestra el código desarrollado en R para la descomposición de la serie temporal de la tasa de desempleo ecuatoriana.

```
# Leer el dataset desempleo.csv
datos <- read.csv("C:/desempleo.csv", header = TRUE, sep = ";")
head(datos)
str(datos)
# Convertir la columna 'desempleo' en una serie temporal mensual
desempleo_ts <- ts(datos$Desempleo, start = c(2002, 1), frequency = 12)
head(desempleo_ts)
# Descomposición aditiva
desempleo_descomposicion <- decompose(desempleo_ts, type = "additive")
plot(desempleo_descomposicion)
# Descomposición con stl
desempleo_stl <- stl(desempleo_ts, s.window = "periodic")
plot(desempleo_stl)
```

Figura 2.6. Código en R para la descomposición de la serie temporal de la tasa de desempleo

Para el análisis de la estacionariedad de la tasa de desempleo en Ecuador, se usó la prueba de Dickey-Fuller aumentada (ADF), la cual mediante la detección de la presencia de raíces unitarias indica si la serie es no estacionaria.

Hipótesis de la prueba ADF:

- **Hipótesis nula (H_0):** La serie tiene una raíz unitaria, lo que significa que no es estacionaria.
- **Hipótesis alternativa (H_1):** La serie es estacionaria (no tiene una raíz unitaria).

Criterio de decisión:

Para tomar una decisión sobre la estacionariedad de la serie, se compara el *p-valor* con un nivel de significancia (α) de 0.05 que es el valor comúnmente utilizado.

- Si **$p\text{-valor} \leq \alpha$** : Se rechaza la hipótesis nula y se concluye que la serie es estacionaria.
- Si **$p\text{-valor} > \alpha$** : No se puede rechazar la hipótesis nula, lo que indica que la serie no es estacionaria.

Según los resultados de la prueba de ADF para la tasa de desempleo (Tabla 2.5.), el $p\text{-valor} = 0.1592$ es mayor que el nivel de significancia típico de 0.05. Esto significa que no se puede rechazar la hipótesis nula de que la serie tiene una raíz unitaria. En los resultados de la prueba no se encuentra suficiente evidencia para concluir que la serie es estacionaria. Se observa que $p\text{-valor} >$ que al nivel de significancia (α) = 0.05 por lo que la serie **no es estacionaria**. Esto sugiere que tiene una tendencia, o que sus propiedades estadísticas (media y varianza) cambian con el tiempo.

La Figura 2.7. muestra el código desarrollado en R para la prueba de ADF de la tasa de desempleo.

Prueba de ADF		
Dickey-Fuller	Lag order	p-value
-2.9934	5	0.1592

Tabla 2.5. Prueba de ADF para el desempleo

```
# Instalar y cargar el paquete tseries
install.packages("tseries")
library(tseries)
# Leer el dataset desempleo.csv
datos <- read.csv("C:/desempleo.csv", header = TRUE, sep = ";")
# Convertir los datos de la tasa de desempleo en una serie temporal mensual
desempleo_ts <- ts(datos$Desempleo, start = c(2002, 1), frequency = 12)
# Realizar la prueba ADF (Dickey-Fuller aumentada)
adf_result <- adf.test(desempleo_ts)
print(adf_result)
```

Figura 2.7. Código en R para la prueba de ADF de la tasa de desempleo

La tasa de desempleo en Ecuador presenta un comportamiento no uniforme, no lineal, estacional y no estacionaria. Esto implica que sus fluctuaciones no siguen un patrón constante en el tiempo, con variaciones regulares debido a factores estacionales como ciclos económicos o eventos recurrentes. Para modelar y predecir este tipo de series, es necesario utilizar técnicas que manejen tanto la estacionalidad como la no estacionariedad, como el modelo SARIMA o la diferenciación de los datos. Además, modelos de aprendizaje automático como las RNNs (LSTM, BiLSTM o GRU) y los modelos de Impulso de Gradiente (Gradient Boosting) como Impulso de Gradiente Extremo (XGBoost) o Máquinas Potenciadas por Gradiente Ligero (LightGBM) son altamente efectivos para capturar patrones temporales complejos, no lineales y con variaciones estacionales, sin la necesidad de suponer estacionariedad en los datos. Estos enfoques proporcionan mayor flexibilidad al modelar series temporales irregulares, adaptándose mejor a las fluctuaciones y dinámicas subyacentes de la tasa de desempleo.

2.3. Fuentes de datos

Los indicadores económicos son recopilados y publicados por una variedad de organizaciones gubernamentales, instituciones financieras, agencias internacionales y empresas privadas en todo el mundo, como gobierno, bancos centrales, instituciones financieras, organizaciones Internacionales y empresas de Investigación.

- **Gobierno:** Los gobiernos a nivel nacional suelen ser los principales productores de datos económicos. Algunas instituciones rectoras de la estadística son:
 - El INEC en Ecuador.

- El Instituto Nacional de Estadística y Geografía (INEGI)⁴ en México.
- El Instituto Nacional de Estadística (INE)⁵ en España.
- La Oficina de Estadísticas Laborales (BLS)⁶, la Reserva Federal (Fed)⁷, el Departamento del Tesoro⁸, el Departamento de Comercio (DOC)⁹ a través de la Oficina de Análisis Económico (BEA)¹⁰, la Oficina del Censo¹¹ y otras divisiones, en Estados Unidos.
- Estas instituciones, departamentos u oficinas recopilan y publican una amplia gama de indicadores económicos, como el PIB, la tasa de desempleo, la inflación, la balanza comercial, entre otros.
- **Bancos centrales:** Los bancos centrales también producen y publican datos económicos importantes, especialmente relacionados con la política monetaria, las tasas de interés y las reservas financieras.
 - La Fed en los Estados Unidos.
 - El Banco Central Europeo¹².
 - Banco de Inglaterra en el Reino Unido¹³.
 - El Banco Central del Ecuador (BCE)¹⁴.
- **Instituciones financieras:** Bancos de inversión, firmas de corretaje y otras instituciones financieras suelen producir sus propios informes y análisis de indicadores económicos para uso interno y para sus clientes. Estos informes pueden incluir proyecciones económicas, análisis sectoriales y recomendaciones de inversión.
- **Organizaciones Internacionales:** Las organizaciones internacionales recopilan datos económicos de diferentes países y los utilizan para realizar análisis comparativos, pronósticos económicos y asesoramiento político. Ejemplos: El Fondo Monetario

⁴ <https://www.inegi.org.mx/>

⁵ <https://www.ine.es/>

⁶ <https://www.bls.gov/>

⁷ <https://www.federalreserve.gov/>

⁸ <https://home.treasury.gov/>

⁹ <https://www.commerce.gov/>

¹⁰ <https://www.bea.gov/>

¹¹ <https://www.census.gov/>

¹² <https://www.ecb.europa.eu/>

¹³ <https://www.bankofengland.co.uk/>

¹⁴ <https://www.bce.fin.ec/>

Internacional (FMI)¹⁵, la Organización para la Cooperación y el Desarrollo Económicos (OECD)¹⁶ y el Banco Mundial¹⁷.

- **Empresas de Investigación:** Empresas de investigación económica y consultoras también producen informes y análisis económicos. Estas empresas suelen trabajar para clientes en el sector privado, ofreciendo perspectivas sobre tendencias económicas y oportunidades de inversión. Ejemplos: la Junta de Conferencias (CB)¹⁸ de Estados Unidos, Thomson Reuters (plataforma Eikon), Bloomberg (plataforma Bloomberg Terminal), entre otros.

2.4. Aprendizaje automático para el análisis predictivo de datos

2.4.1. Introducción al aprendizaje automático para el análisis predictivo de datos

Las organizaciones modernas recopilan enormes cantidades de datos, que adquieren valor una vez que se analizan y se extrae la información necesaria para tomar decisiones más informadas. El *análisis predictivo de datos* es el arte de construir y usar modelos para hacer predicciones basadas en patrones históricos, aplicándose en áreas como predicción de precios, evaluación de riesgos, modelado de propensión, diagnóstico, entre otras. En el análisis de datos, predicción se define ampliamente ya que no siempre se refiere a eventos futuros sino también a la determinación de algo desconocido en algún momento a través de la asignación de valores a variables desconocidas [46], como predecir el precio en el que se venderá un producto en el futuro o predecir el tipo de documento, es decir, la clasificación automática de documentos en categorías específicas (por ejemplo, correos electrónicos de spam o no spam, noticias positivas o negativas, entre otros) basándose en las características del documento (como palabras clave o estructura) y en ejemplos históricos que ha aprendido previamente el modelo.

El Aprendizaje Automático (ML) es un proceso automatizado que identifica patrones en los datos. En el aprendizaje automático supervisado, el proceso se divide generalmente en dos pasos

¹⁵ <https://www.imf.org/>

¹⁶ <https://www.oecd.org/>

¹⁷ <https://www.worldbank.org/>

¹⁸ <https://www.conference-board.org/>

principales llamados entrenamiento y prueba para asegurar que el modelo no solo memoriza los datos de entrenamiento, sino que también puede hacer predicciones precisas en nuevas instancias.

El Aprendizaje Automático (ML) es un proceso automático que se encarga de encontrar patrones en los datos. En el aprendizaje automático supervisado, el proceso se divide normalmente en dos pasos principales conocidos como entrenamiento y prueba, con la finalidad de que el modelo no memorice los datos del entrenamiento y tenga la capacidad de hacer predicciones sobre nuevas instancias del conjunto de datos.

- **Entrenamiento (aprendizaje):** Consiste en que las técnicas de aprendizaje automático supervisado aprenden automáticamente un modelo con capacidad de relacionar las características descriptivas con una característica objetiva utilizando datos históricos (instancias) dentro de un período de muestra. Este período de tiempo incluye los datos de entrenamiento que utiliza el modelo para identificar patrones pertinentes.
- **Prueba (evaluación):** Una vez que el modelo ha sido entrenado se evalúa con un conjunto de datos, conocido como periodo fuera de muestra, que no ha visto antes. Esto permite comprobar la capacidad del modelo para generalizar y hacer predicciones precisas sobre datos nuevos.

Un modelo de predicción muy simple podría resultar coherente con el conjunto de datos, ya que no hay instancias en el conjunto de datos de prueba para las que el modelo no haga una predicción correcta. Sin embargo, en problemas del mundo real en donde se disponga de grandes conjuntos de datos con múltiples características, los modelos de predicción basados en aprendizaje automático es la solución.

El aprendizaje automático funciona mediante algoritmos que exploran un conjunto de modelos predictivos posibles para identificar el que mejor capture la relación entre las características descriptivas y la característica objetivo en un conjunto de datos. El objetivo es encontrar un modelo que no solo sea consistente con los datos de entrenamiento, sino que también generalice bien para hacer predicciones precisas en datos nuevos.

En la búsqueda de modelos predictivos útiles, simplemente buscar modelos que sean consistentes no es suficiente, y hay al menos dos razones para ello:

1. **Ruido en los datos:** Cuando se trabaja con conjuntos de datos grandes, es probable que haya ruido en los datos. El ruido se refiere a errores o imprecisiones en los datos, como valores de características mal etiquetados o información incorrecta. Si el modelo se ajusta demasiado a los datos ruidosos, puede aprender de los errores en lugar de los patrones generales, lo que resulta en predicciones incorrectas; esto se conoce como sobreajuste.
2. **Limitación en la muestra del conjunto de entrenamiento:** En la gran mayoría de los proyectos de aprendizaje automático, el conjunto de entrenamiento es solo una pequeña muestra del total de casos posibles en el dominio a predecir [46]. Esto significa que el problema está mal planteado o definido, ya que no se dispone de suficiente información para encontrar una única solución precisa. Por lo tanto, con los datos disponibles, no es posible determinar un modelo que funcione de manera óptima para todos los casos posibles, porque la muestra es limitada y no abarca todas las situaciones posibles.

El aprendizaje automático enfrenta los desafíos mencionados por lo que encontrar un modelo que generalice correctamente es un problema complejo. Por esta razón, los algoritmos de aprendizaje automático no solo buscan consistencia con los datos, sino que aplican criterios adicionales para identificar el modelo que mejor generaliza en nuevas instancias, básicamente un modelo de aprendizaje automático busca de un conjunto de modelos potenciales el modelo de predicción que generaliza mejor más allá del conjunto de datos de entrenamiento. Los algoritmos utilizan como fuentes de información que guía esta búsqueda, el conjunto de datos de entrenamiento y el *sesgo inductivo* asumido por el algoritmo de aprendizaje automático. El sesgo inductivo puede ser de dos tipos: *sesgo de restricción*, que limita el conjunto de modelos que el algoritmo considerará, y *sesgo de preferencia*, que guía al algoritmo a preferir ciertos modelos sobre otros [46]. El teorema No Free Lunch [47] establece que no hay un sesgo inductivo que sea el mejor en todos los escenarios. La elección del sesgo adecuado depende del problema específico, y no hay garantía de que un sesgo en particular funcione mejor en todos los casos.

Los errores que pueden ocurrir debido a un sesgo inductivo inapropiado en los algoritmos de aprendizaje automático son: subajuste y sobreajuste.

- **Subajuste (Underfitting):** Ocurre cuando el modelo es demasiado simple para capturar la relación subyacente en el conjunto de datos entre las características descriptivas y la característica objetivo.

- **Sobreajuste (Overfitting):** Sucede cuando el modelo es demasiado complejo y se ajusta tan bien a los datos de entrenamiento que también aprende el ruido en esos datos. Esto puede hacer que el modelo funcione mal con datos nuevos.

La Figura 2.8. representa un modelo subajustado que no se ajusta a los datos, ya que no es lo suficientemente complejo como para capturar completamente la relación entre las características descriptivas y la característica objetivo. Luego, se muestra un modelo equilibrado (en su punto justo) que encuentra un buen balance entre el subajuste y el sobreajuste. Por último, el modelo sobreajustado, aunque es consistente con las instancias de entrenamiento, es más complejo de lo necesario, lo que hace que se ajuste excesivamente a los datos de entrenamiento.



Figura 2.8. Subajuste, Equilibrado y sobreajuste [48]

2.4.2. La tabla base analítica y la exploración de datos

Una Tabla Base Analítica (ABT) es una estructura de datos utilizada en proyectos de análisis predictivo que organiza la información en una tabla con características descriptivas y un objetivo de predicción específico (columnas). Cada fila representa una instancia que sirve como base para hacer una predicción.

Por lo general, la ABT se construyen a partir de fuentes de datos de diversa naturaleza sin procesar que están disponibles en una organización. Algunas de estas fuentes de datos son: Base de datos operativa, datos exóticos, archivos planos, almacenes de datos (data warehouse) y data marts, fuentes de datos externas [46]. El diseño de un ABT adecuado implica tener una comprensión previa tanto del negocio como de los datos.

La exploración de datos es una etapa crucial en el desarrollo de la ABT para soluciones de análisis predictivo. Esta fase es parte tanto de la Comprensión de los Datos como de la Preparación de los Datos en el modelo Proceso Estándar Intersectorial para la Minería de Datos (CRISP-DM), que guía el proceso de minería de datos. Antes de desarrollar cualquier modelo predictivo, es fundamental realizar un análisis exploratorio del conjunto de datos del ABT para garantizar que la información se

comprenda bien y que se identifiquen y gestionen adecuadamente los posibles problemas de calidad de los datos. Esto garantiza que los datos sean confiables y estén en un estado óptimo para el modelado, lo que aumenta la precisión y la eficacia del análisis.

La exploración de datos conlleva a plantearse dos objetivos: *Comprender completamente las características de la ABT* como los datos que puede tener cada característica, rangos y distribución de esos valores; aquello va a ayudar a los analistas a familiarizarse con los patrones generales y las peculiaridades de los datos que conlleven a seleccionar las mejores técnicas de modelado. *Verificar si hay problemas de calidad de los datos* que podrían hacer que el modelo no funcione bien, como valores faltantes, valores atípicos (outliers) y niveles inapropiados en ciertas características.

El informe de calidad de datos es una herramienta fundamental para la exploración de datos, ya que proporciona estadísticas descriptivas y visualizaciones como histogramas y gráficos de barras. Ayuda a detectar problemas de calidad de los datos, orienta las estrategias de tratamiento de características, asegurando la solidez de la ABT para producir resultados confiables.

2.5. La predicción de indicadores económicos

La predicción de los principales indicadores económicos clave, como el PIB, la tasa de desempleo, el IPC, la tasa de cambio y la inflación, es esencial para la planificación económica y la formulación de políticas. La comunidad científica ha centrado su atención en la predicción de indicadores económicos como el PIB, tasa de desempleo, índice de precios al consumidor, tasa de cambio, acciones del mercado, consumo de energía, precio de las casas, índice de costos de construcción, tasa del empleo e inflación. La integración de modelos avanzados de aprendizaje automático ha permitido un nivel de precisión sin precedentes en las predicciones, lo cual facilita una mejor comprensión de la dinámica económica y una toma de decisiones más fundamentada. Los trabajos relacionados mencionados en esta tesis fueron obtenidos mediante un método sistemático de revisión, aplicando el método PRISMA y fue basado en artículos científicos publicados en bases de datos reconocidas como la Web of Science (WOS), Scopus y Google Académico [49]. Los apéndices A, B, C, D y E muestra los estudios más relevantes sobre la predicción de los principales indicadores económicos.

La predicción del **PIB** es fundamental para entender y anticipar el crecimiento económico de una región, esto ayuda a la toma de decisiones en política económica y planificación a largo plazo. Estudios recientes han utilizado modelos avanzados de aprendizaje automático, mostrando mejoras

significativas en la precisión de las predicciones. En relación a la predicción del PIB, Marković D. et al. [23] emplearon la Máquina de Aprendizaje Extremo (ELM) en combinación con redes de alimentación directa de una capa oculta para predecir el crecimiento del PIB en la Unión Europea (UE) para capturar la compleja relación entre factores de ciencia y tecnología y el PIB. Este modelo logró un desempeño superior en comparación con los métodos tradicionales de Red Neuronal Artificial (ANN) y Programación Genética (GP).

Otro estudio realizado por Stevanović et al. [50] utilizó ANNs para explorar la relación entre el PIB y el consumo de electricidad en la UE, en donde los resultados mostraron que las redes neuronales entrenadas con métodos de aprendizaje extremo, ofrecieron predicciones satisfactorias del PIB basadas en el consumo de electricidad, sugiriendo una fuerte relación entre estos dos factores.

Asimismo, Marjanović et al. [51] aplicaron la ELM para modelar el vínculo entre las emisiones de dióxido de carbono (CO₂) y el crecimiento del PIB, destacaron que este método es eficaz y rápido para predecir el PIB en función de las emisiones de distintos tipos de combustibles. Los resultados reflejaron una precisión superior de ELM en comparación con ANN y GP, lo que demuestra su capacidad para capturar la influencia de factores medioambientales en el crecimiento económico.

Estos avances muestran como los modelos basados en aprendizaje automático pueden mejorar sustancialmente la capacidad predictiva sobre el PIB, proporcionando una herramienta poderosa para una planificación económica más informada.

Estos avances muestran que los modelos predictivos basados en aprendizaje automático se constituyen en la actualidad en una herramienta poderosa para una planificación económica más informada ya que pueden mejorar sustancialmente la capacidad predictiva sobre el PIB considerando una diversidad de factores claves como ciencia y tecnología, consumo de electricidad y medioambientales.

Para la predicción de la **tasa de desempleo** es fundamental para comprender las dinámicas laborales y evaluar el impacto de las políticas económicas en el mercado laboral. Diversos estudios han empleado métodos avanzados de modelado para mejorar la precisión de las predicciones de la tasa de desempleo, combinando enfoques tradicionales y de aprendizaje automático para capturar mejor las características de cada conjunto de datos. Para la predicción de este índice, Davidescu et al. [52] utilizaron una serie de modelos, como SARIMA y las Redes Neuronales Autorregresivas (NNAR), para pronosticar la tasa de desempleo en Rumania. Los resultados indicaron que el modelo NNAR fue

superior en términos de precisión de pronóstico a corto plazo, mientras que SARIMA se destacó en la exactitud del pronóstico general, especialmente para horizontes de pronóstico extendidos.

Los autores Vosseler y Weber [53] exploraron la precisión predictiva del modelo híbrido Promedio Bayesiano de Modelos y Autorregresivo Periódico (BMA-PAR) frente a los modelos individuales Autorregresivo de Media Móvil Espacial (SARMA), Medias Periódicas (PMEANS) y Autorregresivo Periódico Bayesiano (BPAR) para la predicción del desempleo en Alemania; se encontró que el modelo BMA-PAR incrementa significativamente la precisión en comparación con BPAR especialmente en datos de series temporales complejas que presentan patrones estacionales.

Por otro lado, Katris [54] aplicó el modelo Autorregresivo Integrado de Medias Móviles Fraccionario (FARIMA), ANN y SVM para predecir el desempleo en algunos países europeos. Su estudio encontró que FARIMA era más efectivo en predecir a corto plazo, mientras que las redes neuronales mostraban comparables o superiores resultados a largo plazo.

Asimismo, Shi et al. [55] estudiaron la tasa de desempleo en varios países en desarrollo asiáticos, ellos implementaron el modelo híbrido de Autorregresivo Integrado de Media Móvil y Red Neuronal Autorregresiva (ARIMA-ARNN) para capturar la no linealidades en los datos. Este modelo híbrido demostró un desempeño superior en comparación con los modelos individuales ARIMA, ARNN, ANN y SVM; lo que sugiere que la combinación de enfoques lineales y no lineales puede mejorar notablemente la precisión del pronóstico.

Los enfoques híbridos que combinan modelos de series temporales como ARIMA con redes neuronales tienen mejores resultados en la predicción de las tasas de desempleo. Estos enfoques combinan las fortalezas de ARIMA en la captura de patrones lineales y espaciales con la capacidad de las redes neuronales para manejar relaciones no lineales y estacionales, lo que da como resultado resultados predictivos más precisos y robustos. Otros modelos utilizados incluyen la combinación de LSTM con GRU, redes neuronales como ANN y ARNN, y SVM, que han demostrado ser eficaces en escenarios similares.

Los enfoques híbridos que combinan las fortalezas de ARIMA para capturar patrones lineales y espaciales con la capacidad de las redes neuronales para manejar relaciones no lineales y estacionales tienen mejores resultados en la predicción de las tasas de desempleo. Otros modelos utilizados incluyen la combinación de LSTM con GRU, redes neuronales individuales como ANN y ARNN y SVM; las cuales han demostrado ser eficaces en escenarios similares.

La predicción del **IPC** es crucial para medir la inflación y guiar las políticas monetarias, especialmente en contextos de alta volatilidad económica. Los estudios recientes han desarrollado enfoques avanzados que combinan técnicas lineales y no lineales para mejorar la precisión en las predicciones del IPC. En concordancia a este tipo de predicción, Eklund y Kim [56] exploraron un modelo de regresión de cópula gaussiana, empleando datos de sentimiento del Comité Federal de Mercado Abierto (FOMC) y el Índice Nacional de Condiciones Financieras (NFCI) para predecir el IPC en Estados Unidos. Los resultados mostraron que el modelo basado en cópula gaussiana con matriz de correlación de Modelo Autorregresivo de Media Móvil, ARMA(1,0), logró el mejor desempeño en términos de precisión, superando los modelos de regresión lineal simples, especialmente al capturar relaciones no lineales en los datos.

Zeng et al. [57] introdujeron un modelo de números difusos triangulares y redes neuronales, combinando el Modelo Gris de Números Difusos Triangulares con Redes Neuronales (NNTFGM (1, 1)) para capturar las fluctuaciones del IPC en China. Este modelo permitió representar la incertidumbre en los datos y ajustar las predicciones de manera más precisa en comparación con modelos difusos simples, lo que es útil para series con alta variabilidad.

Por otro lado, Wang et al. [58] desarrollaron un modelo híbrido Autorregresivo Integrado de Medias Móviles con Retropropagación (ARIMA-BP) para pronosticar el IPC de China. Este modelo integró un enfoque de series temporales ARIMA para capturar las tendencias lineales, seguido de una red neuronal de Retropropagación (BP) para modelar las partes no lineales de la serie. Los resultados demostraron que este enfoque híbrido proporciona predicciones más precisas que los modelos individuales, aprovechando las fortalezas de ambos métodos para capturar patrones complejos en los datos del IPC.

Estos modelos avanzados y combinados en la predicción del IPC permiten un análisis más robusto, adecuado para gestionar políticas económicas en entornos de cambio constante y ofrecer una mayor precisión para la toma de decisiones en materia de inflación y estabilidad económica.

La predicción de la **tasa de cambio** es fundamental para la planificación financiera y el manejo del riesgo en los mercados globales, ya que las fluctuaciones en los tipos de cambio impactan significativamente en el comercio, la inversión y las políticas monetarias. En este ámbito, los modelos híbridos y avanzados de aprendizaje automático han mostrado una gran efectividad al capturar patrones no lineales y variables económicas complejas. Por ejemplo, Lu et al. [59] propusieron un modelo híbrido que combina Redes de Creencias Profundas (DBN) con redes LSTM para predecir el

tipo de cambio del Renminbi (RMB) frente al Dólar Estadounidense (USD). Este modelo demostró un rendimiento superior en comparación con enfoques tradicionales como el Modelo Autorregresivo de Media Móvil - Heterocedasticidad Condicional Autorregresiva Generalizada (ARMA-GARCH), logrando una precisión del 74.92% en la predicción del tipo de cambio y destacándose en la medición de riesgo mediante el método Valor en Riesgo (VaR).

Por otro lado, Luo et al. [60] extendieron el modelo Heterocedasticidad Condicional Autorregresiva Generalizada con Muestreo de Datos Mixtos (GARCH-MIDAS) para la predicción de la volatilidad del tipo de cambio de Dólar Estadounidense a Yuan Chino USD/CNY, incorporando índices de indefinición como el Índice de Incertidumbre en la Política Comercial de Estados Unidos (USTPU). Este enfoque demostró una mejora significativa en la precisión predictiva, especialmente en momentos de alta volatilidad geopolítica, como el conflicto entre Rusia y Ucrania.

Adicionalmente, Wang et al. [61] emplearon un modelo de Redes Neuronales Convolucionales con Memoria a Largo y Corto Plazo con Tangente Hiperbólica (CNN-TLSTM) para predecir el precio de cierre del tipo de cambio USD/CNY, integrando redes convolucionales para extraer características y una variante de LSTM para manejar series temporales; el modelo mostró un rendimiento sobresaliente con menores errores en predicciones a corto plazo vs. los modelos individuales como Perceptrón Multicapa (MLP) y la Red Neuronal Recurrente (RNN).

Estos avances subrayan la importancia de los modelos híbridos y las técnicas de aprendizaje profundo para abordar la complejidad y volatilidad en la predicción de tasas de cambio, proporcionando herramientas más precisas y confiables para el análisis económico y financiero.

Finalmente, la predicción de la **inflación** es un aspecto crucial en la economía, dado que influye en las decisiones de política monetaria y en la estabilidad económica de un país. Diversos enfoques avanzados de modelado han mejorado la capacidad de predecir con precisión las fluctuaciones inflacionarias, utilizando tanto modelos econométricos como métodos de aprendizaje automático.

Por ejemplo, Constantino et al. [39] aplicaron el modelo SARIMA para predecir la inflación en Brasil, basándose en el Índice Nacional de Precios al Consumidor Amplo (IPCA). El modelo mostró una eficiencia del 95% al capturar tanto los patrones estacionales como no estacionales en los datos históricos de inflación, lo que permite estimaciones más precisas de las tendencias inflacionarias futuras.

En un estudio sobre la inflación en China, Wang et al. [62] emplearon el modelo Autorregresivo Funcional (FAR) basado en el método de estimación de Splines Base (Basis Splines) para capturar la tasa de crecimiento del IPC en periodos estables, como la "nueva normalidad" de la economía China. El FAR superó al modelo ARMA en predicciones a largo plazo, mostrando un desempeño superior en momentos de baja volatilidad.

Los autores Yang y Guo [63] utilizaron Redes Neuronales Recurrentes con Unidad Recurrente Cerrada (GRU-RNN) para modelar la inflación en China para ello integraron múltiples variables económicas en un vector de características. Este enfoque basado en aprendizaje profundo ofreció un desempeño notable ya que logró menores errores en la predicción del IPC en comparación con modelos tradicionales como ARMA.

Estos novedosos modelos combinados avanzados en la predicción de la inflación demuestran como el empleo de técnicas complejas pueden prever con mayor precisión los movimientos inflacionarios, brindando a quienes toman decisiones políticas herramientas robustas para enfrentar desafíos económicos en entornos de alta volatilidad y complejidad.

La combinación de métodos tradicionales con técnicas de aprendizaje automático aumenta la precisión en la predicción de estos indicadores económicos clave y brinda a los formuladores de políticas una herramienta eficaz para gestionar mejor la volatilidad e incertidumbre en el entorno económico actual [45], [55], [58], [64], [65], [66], [67], [68], [69].

La Tabla 2.6. resume los principales modelos de IA utilizados en la predicción de indicadores económicos.

Modelos de IA utilizados en la predicción de indicadores económicos		
Indicador económico predicho	Métodos de IA	Número de artículos de investigación
PIB	<ul style="list-style-type: none"> • Máquina de Aprendizaje Extremo (ELM) • Redes Neuronales Artificiales (ANNs) • Análisis Wavelet con Memoria a Largo y Corto Plazo (WA-LSTM) • Unidades Recurrentes Cerradas (GRU) • Red Convolutiva Temporal (TCN) • Regresión de Vectores de Soporte (SVR) • Máquina de Aprendizaje Extremo y Colonia de Abejas Artificiales (ELM-ABC) • Memoria a Largo y Corto Plazo con Optimización por Enjambre de Partículas (LSTM-PSO) 	[23], [50], [51], [70], [71], [72], [73], [74], [75]

Tasa de desempleo	<ul style="list-style-type: none"> • Redes Neuronales Artificiales (ANNs) • Redes Neuronales Autorregresivas (ARNN) • Máquinas de Vectores de Soporte (SVM) • Modelos híbridos: Autorregresivo Integrado de Media Móvil - Redes Neuronales Artificiales (ARIMA-ANN), Autorregresivo Integrado de Media Móvil - Máquinas de Vectores de Soporte (ARIMA-SVM), ARIMA-ARNN. • Modelo híbrido de Memoria a Largo y Corto Plazo y Unidades Recurrentes Cerradas (LSTM-GRU) 	[33], [34], [55], [56], [57]
Índice de precios al consumidor	<ul style="list-style-type: none"> • Redes Neuronales Artificiales (ANNs) • Máquinas de Vectores de Soporte (SVR) • Modelos híbridos: ARIMA-BP, Red Neuronal Artificial y Optimización por Enjambre de Partículas (ANN-PSO) • Programación Genética (GP) • Modelos con enfoque difuso 	[57], [58], [79], [80], [80], [81]
Tasa de cambio	<ul style="list-style-type: none"> • Redes de Creencias Profundas y Memoria a Largo y Corto Plazo (DBN-LSTM) • Modelos Híbridos de Descomposición: Descomposición Empírica de Modos, Memoria a Largo y Corto Plazo con Regresión de Vectores de Soporte (EMD-LSTM-SVR), Heterocedasticidad Condicional Autorregresiva Generalizada - Muestreo de Datos Mixtos (GARCH-MIDAS) • Redes Neuronales Convolucionales con Memoria a Largo y Corto Plazo con Tangente Hiperbólica (CNN-TLSTM) • Operador de Selección y Contracción Mínima Absoluta - Memoria a Largo y Corto Plazo Bidireccional (LASSO-BiLSTM) • Descomposición Modal Variacional, Descomposición Completa Empírica de Modos con Ruido Adaptativo, Unidades Recurrentes Cerradas y Red Convolutiva Temporal Basada en Atención (VMD-CEEMDAN-GRU-ATCN) 	[59], [60], [61], [65], [66], [68]
Inflación	<ul style="list-style-type: none"> • Red Neuronal con Modelo Autorregresivo No Lineal con Variables Exógenas (NARX-NN) • Unidad Recurrente Cerrada y Red Neuronal Recurrente (GRU-RNN) • Árbol de Modelos Lineales Locales (LoLiMoT) • Bosque Aleatorio (Random Forest) • Aumento de Gradiente (Gradient Boosting) • Regresión por Vectores de Soporte (SVR) • Impulso de Gradiente Extremo (XGBoost) • Perceptrón Multicapa (MLP) • ANNs 	[41], [63], [69], [82], [83], [84], [85]

Tabla 2.6. Modelos de IA utilizados en la predicción de indicadores económicos

La predicción de indicadores económicos utilizando modelos de IA se ha consolidado como una herramienta precisa y eficaz para el seguimiento de la dinámica de estos índices. Los hallazgos obtenidos al implementar estos modelos proporcionan una sólida evidencia de utilidad para los formuladores de políticas económicas ya que pueden sustentar sus estrategias con mayor certeza y anticipación. Indicadores como el PIB, la tasa de desempleo, el IPC, la tasa de cambio y la inflación son métricas cruciales que reflejan la salud económica de un país y brindan información relevante sobre las variaciones económicas actuales y futuras. Estas estadísticas también son esenciales para los agentes económicos al momento de tomar decisiones de inversión y evaluación de riesgos.

Según la revisión de los artículos científicos más relevantes acerca de la predicción de indicadores económicos, los modelos de IA más usados en el campo de la predicción son las Redes Neuronales de Retropropagación (BPNN) y las redes neuronales recurrentes LSTM y GRU para estimar el PIB y la tasa de desempleo; y los modelos SVR y CNN usados para capturar patrones no lineales en la predicción del IPC y la tasa de cambio. También destacan los sistemas híbridos los cuales integran varios modelos de IA o de aprendizaje profundo con enfoques tradicionales, los cuales han demostrado su capacidad para optimizar la precisión de los índices económicos caracterizados por en contextos de alta volatilidad y sensibilidad a factores externos. Cada modelo predictivo tiene diferentes capacidades en cuanto a exactitud y versatilidad, se constituyen en instrumentos esenciales que aportan información predictiva valiosa de indicadores económicos consumida por los responsables de realizar análisis y tomar decisiones estratégicas en distintos ámbitos sea empresarial, gubernamental, financiero o económico.

2.6. Algoritmos de IC aplicados en la predicción de la tasa de desempleo

El estudio, diseño y desarrollo de métodos computacionales inspirados en los procesos naturales, como los biológicos y lingüísticos, se conoce como *Inteligencia Computacional (IC)*. Estos métodos se utilizan para resolver problemas complejos en diversos campos mediante el aprendizaje y la adaptación a procesos naturales, como los que ocurren con los seres humanos y otros seres vivos. Tradicionalmente, los tres pilares principales de IC han sido las redes neuronales, los sistemas difusos y la computación evolutiva. Al respecto [86] considera que los cinco enfoques básicos de la inteligencia computacional son: Lógica difusa, Computación evolutiva, Redes neuronales, Inteligencia de enjambre, Métodos probabilísticos y Teoría del aprendizaje. Tradicionalmente. Hoy en día a más de estos componentes la IC abarca paradigmas informáticos como la inteligencia

ambiental, la vida artificial, el aprendizaje cultural, las redes endocrinas artificiales, el razonamiento social y las redes de hormonas artificiales [87].

Por lo tanto, las técnicas de inteligencia computacional, que incluyen redes neuronales, sistemas difusos, computación evolutiva, inteligencia de enjambre, métodos probabilísticos, teoría del aprendizaje y otras estrategias, buscan imitar comportamientos humanos, como la percepción, el razonamiento, el aprendizaje, la evolución y la adaptación; así como, patrones de comportamiento animal tales como pájaros, hormigas y abejas.

Los *Algoritmos Evolutivos (EA)* son métodos de búsqueda y optimización estocásticos basados en la herencia genética y la evolución darwiniana. Entre ellos, los GA son métodos de optimización empleados para resolver problemas no lineales, no diferenciables, discontinuos o multimodales. Operan comenzando con una generación inicial de soluciones candidatas, que evolucionan a través de operadores genéticos de selección, cruce y mutación, optimizando la bondad de las soluciones basándose en una función de aptitud. Los GA se han aplicado ampliamente a redes neuronales, mejorando algoritmos de aprendizaje, selección de subconjuntos de características y optimización de la topología de redes neuronales. Se propone emplear un enfoque híbrido GA-LSTM para determinar el tamaño de la ventana temporal y el número de unidades LSTM, lo cual es crucial para el rendimiento del algoritmo.

Algunos algoritmos de Inteligencia Computacional (IC) aplicados en la predicción de la tasa de desempleo son: Algoritmos de Redes neuronales como ANN y RNN, y de Computación Evolutiva como GA.

2.6.1. Red neuronal artificial (ANN)

Una ANN es un modelo computacional capaz de capturar complejos modelos no lineales. Una red neuronal es análoga a la forma en que el cerebro humano procesa la información, el cerebro humano está compuesto por miles de millones de células llamadas neuronas que se conectan entre sí por medio de la sinapsis neuronal para transmitir informaciones sensitivas, esta comunicación se da de manera efectiva gracias a los axones derivados del cuerpo natural de la neurona; de manera similar, las ANNs están formadas por nodos (análogos a las neuronas) y estos nodos están conectados entre sí a través de bordes (análogos a los axones y sinapsis de las neuronas) (Figura 2.9.). Una ANN se compone de una capa de entrada con nodos de entradas, una o varias capas ocultas con nodos ocultos y una capa de salida con uno o varios nodos de salida. Entre dos capas de

neuronas existe una red de pesos de conexión, que puede ser hacia delante, hacia atrás, lateral y de retardo. Un nodo de una red neuronal artificial toma una combinación lineal de entrada de las neuronas de la capa anterior y luego aplica la función de activación (como sigmoide, tangente hiperbólica, unidad lineal rectificada, entre otras) en la capa oculta para generar la salida final.




Figura 2.9. Redes neuronales biológicas (A, C) y artificiales (B, D) [88]

2.6.2. Red neuronal recurrente (RNN)

Las RNN son un modelo conexionista que contiene una capa oculta auto conectada, desarrolladas en la década de 1980 [89], esta red de nodos (llamados también neuronas) son parecidos a las neuronas, en la que cada neurona está conectada direccionalmente con todas las demás. Las neuronas en una RNN se pueden dividir en neuronas de entrada (que reciben datos desde fuera de la red), neuronas de salida (que producen resultados) y neuronas ocultas (que modifican los datos en el camino de la entrada a la salida). Cada neurona tiene una activación de valor real variable en el tiempo y cada borde dirigido (sinapsis) tiene un peso de valor real modificable [90]. Las RNN se han adoptado ampliamente en áreas de investigación relacionadas con reconocimiento de voz, procesamiento de lenguaje natural, traducción de idiomas, subtítulos de imagen, reconocimiento de acciones, detección y seguimiento de objetos, segmentación de imágenes, entre otros [91], [92], [93], [94], [95], [96], [97].

Las RNN son una clase de redes neuronales que permiten que las salidas anteriores se usen como entradas mientras tienen estados ocultos. En una RNN se tiene una entrada X_t , luego se realizan algunas operaciones y se obtienen estados ocultos S_t , luego mediante un bucle se toman estos

estados ocultos y se vuelven a ubicar en el siguiente paso, para de esta manera usar el conocimiento previo y actualizar el nuevo estado, finalmente obtenemos una salida y_t . La configuración RNN se puede representar de forma enrollada y desenrollada sobre la secuencia de entrada (Figura 2.10.).




Figura 2.10. RNN enrollada y desenrollada

Para cada paso de tiempo t , la activación $s^{<t>}$ y la salida $y^{<t>}$ se expresan de la siguiente manera:

$$s^{<t>} = g_1 (W_{aa}s^{<t-1>} + W_{ax}x^{<t>} + b_a), y^{<t>} = g_2 (W_{ya}s^{<t>} + b_y) \quad (2)$$

Donde $W_{aa}, W_{ax}, W_{ya}, b_a, b_y$ son coeficientes que se comparten temporalmente y g_1, g_2 son las funciones de activación.

Una de las desventajas de las redes RNN es que tiene dificultades para aprender dependencias de tiempo largas que tienen más de unos pocos pasos de tiempo [98] debido al problema de gradientes que se desvanecen y explotan. Para superar esto, proponemos una arquitectura híbrida GA-LSTM, ya que LSTM es capaz de manejar dependencias a largo plazo del orden de más de 1000 pasos de tiempo discretos [99] y GA permite determinar el tamaño de la ventana y la topología de la red. Las arquitecturas variantes de RNN son la memoria a corto y largo plazo, la memoria a corto y largo plazo bidireccional y las unidades recurrentes cerradas.

2.6.2.1. Memoria a largo y corto plazo (LSTM)

La LSTM son un tipo especial de RNN, fueron diseñadas para resolver el problema del gradiente de fuga de las redes RNN clásicas. Las redes LSTM están compuestas por módulos (llamados también celdas). Un módulo LSTM consta internamente de tres puertas (olvido, entrada y salida) que regulan el flujo de información en un módulo LSTM (Figura 2.11.). La LSTM tiene la capacidad de eliminar o agregar información al estado de la celda, cuidadosamente regulado por estructuras llamadas puertas. La *puerta de olvido* consiste en una capa sigmoidea y una operación

de multiplicación de manera similar a la *puerta de salida* que adicionalmente tiene una operación tangente hiperbólica, mientras que la *puerta de entrada* tiene dos capas: la sigmoidea y la tangente hiperbólica; así como, las operaciones de multiplicación y de adición. La puerta de olvido controla cuando se olvida o recuerda una información mediante una función sigmoidea. La puerta de entrada ayuda a actualizar el estado de la celda, la información de la entrada actual y del estado previo pasa por la función Sigmoide y la función Tangente Hiperbólica (tanh) que actualizarán y reducirán los valores respectivamente para regular la red; además, la salida sigmoide decidirá qué información es importante mantener de la salida tangente. En base a la información de la puerta oculta y la puerta de entrada se calcula el estado de la celda; así como, de las operaciones de multiplicación y producto, para obtener el nuevo estado celular. Por último, la puerta de salida decide cuál debería ser el siguiente estado oculto.

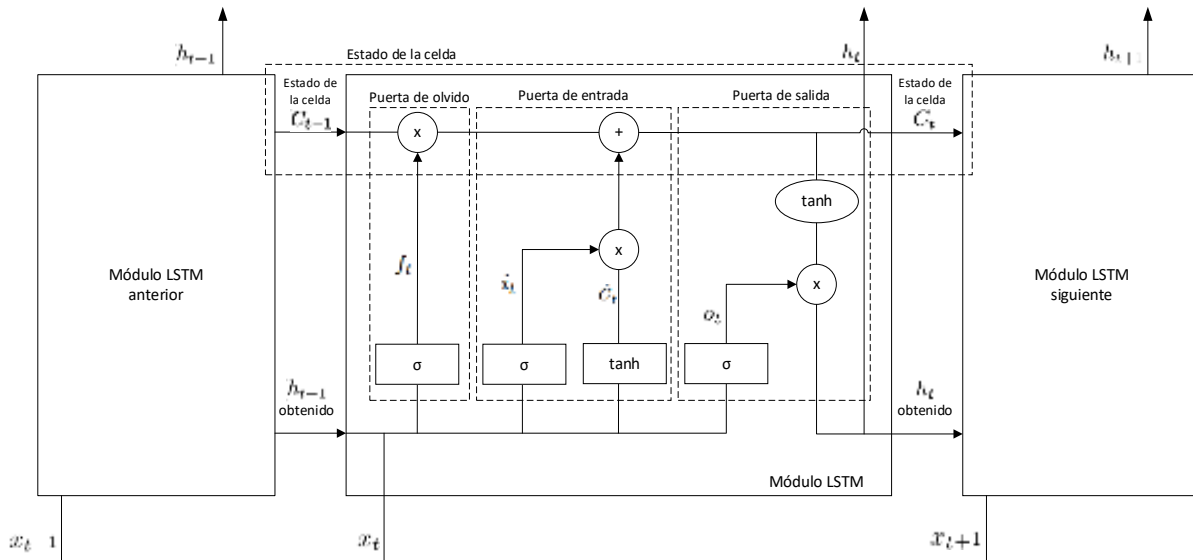


Figura 2.11. Esquema general de una red neuronal LSTM para x_t . Se puede observar la interacción entre los módulos LSTM y los tipos de puertas que componen un módulo LSTM

La red propuesta en este trabajo es multivariada, es decir, toma varias variables de entrada y obtiene una sola variable de salida, dado que el objetivo de la investigación es predecir la variable continua de desempleo; LSTM se combina con el GA para la determinación de los factores arquitectónicos de la red neuronal, tal como se describió en el apartado 2.6.4. Así, para la predicción de los últimos 22 meses del conjunto de datos se realizarán los modelos BiLSTM y GRU como enfoques de referencia frente a la predicción de los últimos 19 meses del modelo híbrido LSTM-GA.

2.6.2.2. Memoria a largo y corto plazo bidireccional (BiLSTM)

Una BiLSTM es un tipo de red neuronal recurrente en donde la señal se propaga hacia atrás y hacia adelante en el tiempo, es decir, permite un entrenamiento adicional al atravesar los datos de entrada dos veces: de izquierda a derecha y de derecha a izquierda [100]. BiLSTM ha demostrado buenos resultados en muchos campos como el procesamiento del lenguaje natural, segmentación semántica del complejo QRS, predicción o pronóstico de series temporales, clasificación de fonemas, entre otros [100], [101], [102], [103], [104], [105]. La estructura de una capa BiLSTM desplegada que contiene una capa LSTM directa y una capa LSTM inversa se ilustra en la Figura 2.12.

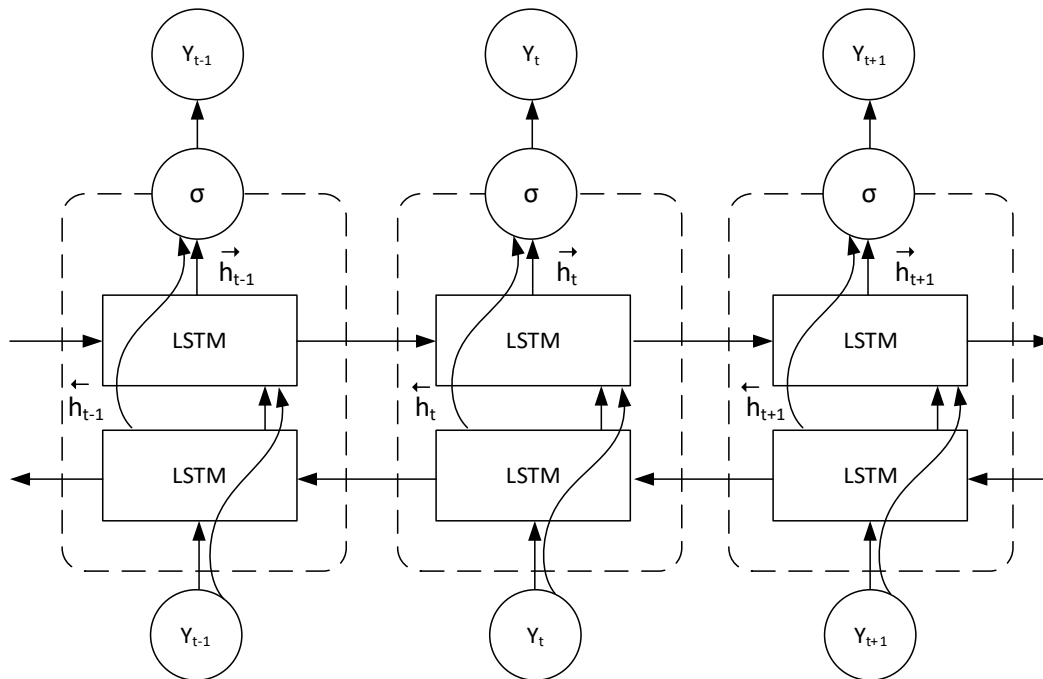


Figura 2.12. La arquitectura desplegada de BiLSTM con tres pasos consecutivos [106]

Como la secuencia de salida de la capa LSTM directa \vec{h} , se obtiene de manera común como la unidireccional, la secuencia de salida de la capa LSTM inversa \overleftarrow{h} , se calcula utilizando las entradas inversas desde el tiempo $t - 1$ hasta el $t - n$. Estas secuencias de salida luego se alimentan a la función σ para combinarlas en un vector de salida y_t [107]. Similar a la capa LSTM, la salida final de una capa BiLSTM se puede representar mediante un vector, $Yt = [y_{t-n}, \dots, y_{t-1}]$, en el que el último elemento, y_{t-1} , es la tasa de desempleo estimada para la próxima iteración.

2.6.2.3. Unidades recurrentes cerradas (GRU)

Las GRU son similares a las LSTM, fueron creadas para solucionar el problema de gradiente de fuga, para ello usa dos puertas (reinicio y actualización) en lugar de tres puertas que utiliza LSTM.

La puerta de reinicio es usada para determinar cuánta información del pasado olvida y la puerta de actualización decide la información a desechar y la información nueva a agregar. En la estructura GRU, la puerta de reinicio r selecciona información del estado anterior h para ser descartada y la puerta de actualización z selecciona nueva información del vector de entrada y y el estado anterior h para agregarla a un nuevo estado. El candidato para el futuro estado oculto se encuentra mediante la puerta de estado candidato g [108]. En comparación con un modelo basado en LSTM, un modelo basado en GRU tiene una estructura más sencilla y menos operaciones de tensor (alrededor de un 25 % menos) debido a la fusión del estado celular y el estado oculto, lo que facilita el entrenamiento del modelo y lo convierte en un candidato muy apropiado para implementaciones integradas [109] (Figura 2.13.).

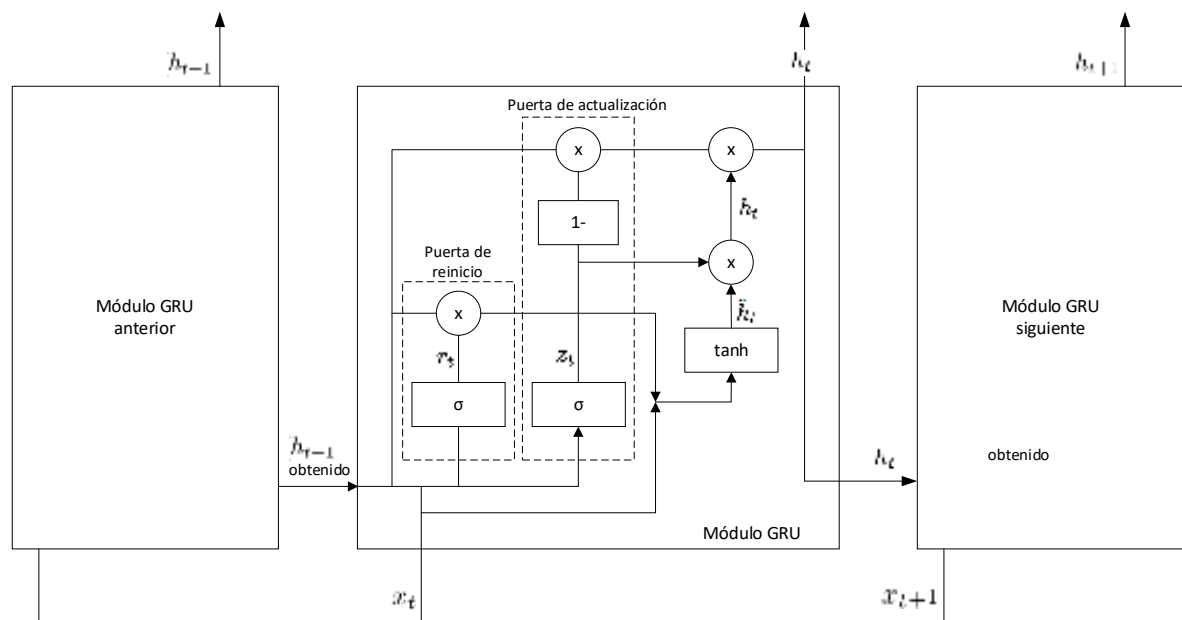


Figura 2.13. La estructura de la celda de memoria de la unidad recurrente cerrada [109]

2.6.3. Algoritmos genéticos

Los Algoritmos Genéticos (GAs) constituyen una clase destacada de técnicas de optimización inspiradas en los principios de la evolución biológica. Estos algoritmos se han aplicado en diversos ámbitos por su eficacia en la búsqueda de soluciones óptimas, las aplicaciones incluyen la optimización de diseños de ingeniería, la selección de características y la optimización de los hiperparámetros y la arquitectura de los modelos de aprendizaje automático, la creación de robots

autónomos, entre otros [110], [111], [112]. El GA fue propuesto por JH Holland en 1992 [113], emulan el proceso de selección natural, imitando la supervivencia darwiniana del más apto.

Sourabh Katoch et al. [113] destacan el parecido de los GAs con la genética natural. Los GAs utilizan cromosomas con formato de cadenas binarias, en las que cada locus tiene dos posibles alelos: 0 y 1; las diferentes soluciones de un problema se representan en GA como cromosomas de individuos. En otros enfoques los parámetros del espacio de búsqueda se codifican en forma de valores reales, permutaciones, cadenas, entre otras. Así mismo, el concepto de cromosoma coincide con las observaciones de Deb Kalyanmoy [114] de que los GAs son robustos y se basan en una representación cromosómica de las soluciones, lo que permite explorar eficazmente los espacios de soluciones. Una colección de tales cromosomas se llama población. Inicialmente, se crea una población aleatoria, que representa diferentes puntos en el espacio de búsqueda.

En el GA la función de aptitud evalúa el mérito de los cromosomas mediante la métrica RMSE y se aplican los operadores genéticos de selección, cruce y mutación con la finalidad de generar mejores soluciones en cada generación, siendo el proceso iterativo hasta que se alcance un criterio de parada. Esto concuerda con lo indicado por Pál Károly [115], quien menciona que los GA inician el proceso de búsqueda con una población de soluciones y la mejoran progresivamente mediante la reproducción, el cruce y la mutación. La selección se inspira en la supervivencia del más apto y guía la evolución de las soluciones, permitiéndoles explorar múltiples regiones y eludir los óptimos locales. En el algoritmo híbrido GA-LSTM la operación de selección es por el método de la ruleta en donde los individuos con mejor fitness son más probables de que sean elegidos para la siguiente generación, el cruce es del tipo ordenado que combina dos cromosomas para generar un nuevo individuo y la mutación es del tipo por intercambio de índices en donde se seleccionan al azar dos posiciones dentro del cromosoma y se intercambian considerando una probabilidad definida del 60 por ciento.

Los algoritmos genéticos constituyen un potente paradigma de optimización inspirado en la evolución natural. Los principios fundamentales son el uso de cromosomas, la selección basada en la aptitud y operadores genéticos como la reproducción, el cruce y la mutación. Los GAs buscan eficazmente soluciones óptimas para una amplia gama de problemas, lo que los convierte en una herramienta versátil y de gran impacto en el campo de la optimización. Además, la combinación sinérgica de estos enfoques con otros procedimientos de búsqueda como la optimización local puede llevar a una exploración más completa y efectiva de los espacios de soluciones.

Los algoritmos genéticos optimizan los parámetros buscando la solución óptima, estabilizando primero los parámetros más importantes y después aquellos que influyen poco en los resultados del modelo. Asimismo, se usan los GAs para seleccionar de manera eficaz los componentes principales (PC), es decir, los subconjuntos de factores que proporcionan el mejor modelo de calibración y mejoran la precisión del modelo. Los GAs permiten identificar las combinaciones de factores que optimizan un modelo, evitando tanto el sobreajuste como el subajuste de factores relevantes. La justificación para aplicar un algoritmo genético para la selección de factores radica en el hecho de que se minimiza el riesgo de pasar por alto una solución potencialmente interesante [116], [117].

2.6.4. Modelo híbrido GA-LSTM

El modelo híbrido GA-LSTM combina la arquitectura LSTM para abordar problemas complejos de predicción de series temporales junto a la capacidad de optimización de los GA. Los GA son métodos de búsqueda y optimización estocásticos inspirados en los principios de la genética y selección natural, operan generando una población inicial de soluciones candidatas que evolucionan a través de operadores genéticos definidos como selección, cruce y mutación; promoviendo una población óptima. GA es útil para resolver problemas complejos no lineales, no diferenciables y multimodales [118], [119], [120]. En el contexto de redes neuronales, los GA se han aplicado exitosamente para mejorar los algoritmos de aprendizaje, seleccionar subconjuntos de características de entre varias de un conjunto de datos y optimizar configuraciones topológicas de redes neuronales.

Por otro lado, las LSTM son un modelo variante de las RNN usadas para manejar datos secuenciales diseñadas mediante celdas de memoria y puertas de control que les permiten capturar dependencias a largo plazo y adaptarse a corto plazo, gestionando información relevante a lo largo del tiempo. Una unidad LSTM se compone típicamente de una celda de memoria y tres puertas principales: una puerta de entrada, una puerta de olvido y una puerta de salida [121]; además de un conjunto de pesos con el objeto de transformar las entradas y regular el flujo de información de la red.

Combinar estas estrategias mediante el enfoque GA-LSTM ajusta con precisión los elementos de duración de la ventana de tiempo y la cantidad de unidades del modelo LSTM para elevar la eficacia del algoritmo en la predicción de los valores de la tasa de desempleo. Los GA gestionan la exploración del espacio de soluciones posibles para descubrir las mejores configuraciones óptimas, valorando cada posible solución usando la función de aptitud basada en la métrica RMSE. Este método

garantiza la adecuada configuración de la red neuronal LSTM, maximizando su capacidad para identificar y comprender los patrones complejos y no lineales en el conjunto de datos.

La Figura 2.14 ilustra la arquitectura conceptual del modelo híbrido GA-LSTM se destaca como los GA optimizan los hiperparámetros de las LSTM y facilitan su integración en un marco predictivo robusto. Este enfoque aprovecha las fortalezas de ambos métodos y constituye una herramienta avanzada para resolver problemas predictivos en dominios económicos y otros campos con datos secuenciales.

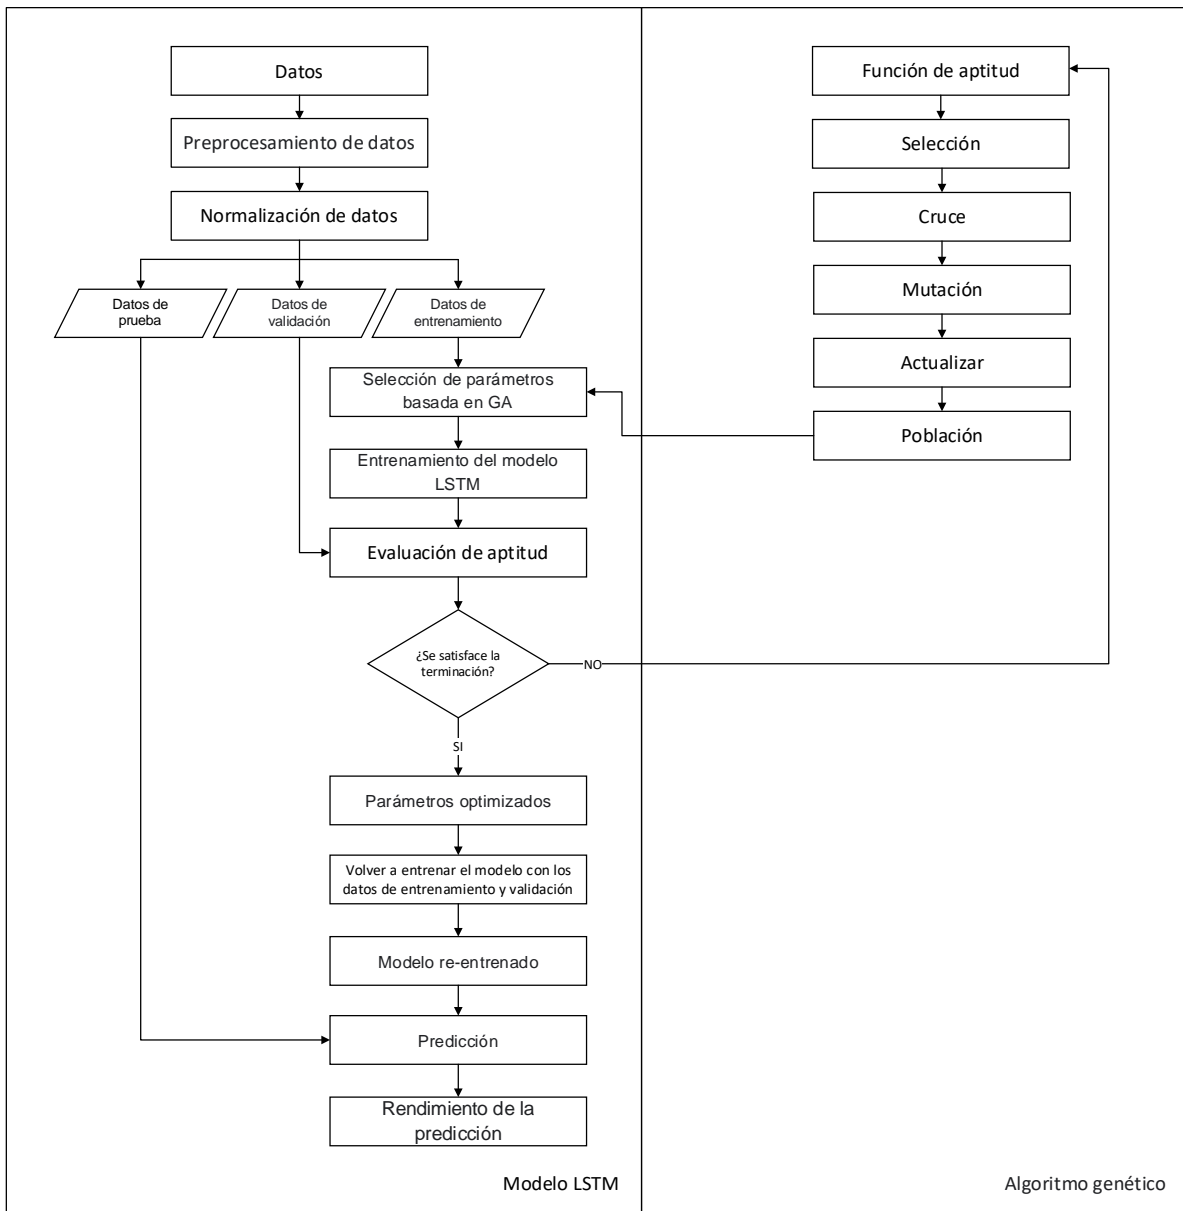


Figura 2.14. Modelo GA-LSTM para la predicción de la tasa de desempleo

En este capítulo se detalla el enfoque metodológico seguido en la tesis doctoral. Se describe el proceso de recopilación, preprocesamiento y análisis exploratorio de los datos utilizados, asegurando su calidad y relevancia para los objetivos planteados. Además, se expone el diseño e implementación del modelo híbrido basado en redes neuronales LSTM optimizadas mediante algoritmos genéticos, especificando los parámetros utilizados y las técnicas de validación aplicadas. Este capítulo también incluye una explicación del esquema experimental y las métricas empleadas para evaluar el desempeño de los modelos propuestos frente a enfoques alternativos.

3.1. Planteamiento del problema

Predecir las tasas de desempleo es un tema crucial tanto en el ámbito económico como social, especialmente en economías emergentes como Ecuador, donde las fluctuaciones en el desempleo pueden desencadenar consecuencias económicas significativas. La naturaleza compleja y no lineal de los factores que influyen en el desempleo, como el PIB, la inflación, la FBCF y el salario mínimo, plantea desafíos únicos en la precisión de su predicción. Además, en la nación ecuatoriana, la disponibilidad y cobertura temporal de los datos se encuentran limitadas en comparación con otros contextos globales, lo cual dificulta la adaptación de los modelos de predicción convencionales al contexto nacional.

A pesar de los avances en el desarrollo de modelos predictivos, existen brechas en la capacidad de los modelos actuales para capturar y anticipar de manera precisa los efectos de eventos no reflejados completamente en los datos del mercado laboral. Esto genera una necesidad de modelos avanzados y flexibles que puedan manejar la incertidumbre inherente en los datos y que se adapten a los cambios estructurales en la economía. Para abordar estas limitaciones, esta investigación propone un modelo híbrido que combina RNN de tipo LSTM con GA para optimizar los parámetros de la red y mejorar la precisión de las predicciones (ver Sesión 3.2.3.1. Algoritmo híbrido GA-LSTM). Este enfoque pretende llenar la brecha existente al proporcionar una metodología que no solo

capture las dinámicas complejas del mercado laboral ecuatoriano, sino que también ajuste sus predicciones de acuerdo con la variabilidad de sus datos.

El problema central de esta investigación radica en evaluar la efectividad del modelo híbrido GA-LSTM en comparación con otros modelos recurrentes, como BiLSTM y GRU, para determinar el modelo más adecuado en la predicción de la tasa de desempleo en el país.

3.2. Solución propuesta y esquema metodológico

La investigación tiene como objetivo desarrollar un sistema de predicción robusto que integre la optimización genética y redes recurrentes del tipo LSTM, capaz de mejorar los pronósticos de la tasa de desempleo y adaptarse dinámicamente a los patrones económicos de Ecuador, utilizando datos de desempleo de los últimos diecinueve meses; y comparar su funcionamiento con otras redes neuronales recurrentes BiLSTM y GRU.

El autor de esta tesis planteó el proceso descrito en la Figura 2.15., el cual se compone de cuatro fases principales y sus etapas correspondientes para la predicción de la tasa de desempleo

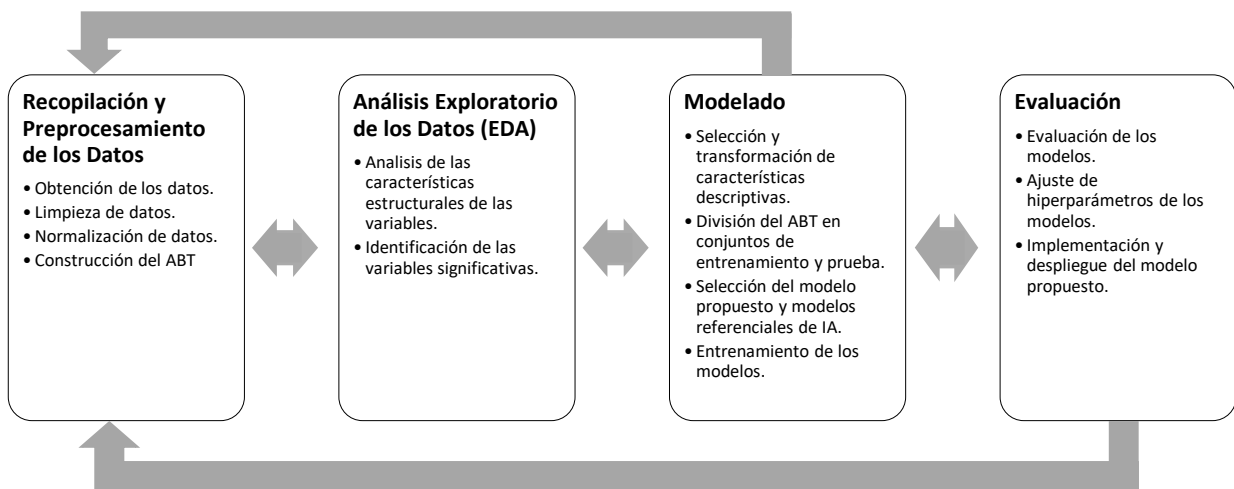


Figura 2.15. Fases y etapas del proceso de predicción de la tasa de desempleo

A continuación, se describe brevemente cada una de las etapas de la metodología de predicción.

1. Recopilación y Preprocesamiento de los Datos.

- **Obtener los datos:** Recolectar los datos económicos confiables de la inflación, salario mínimo, PIB, formación bruta de capital fijo y tasa de desempleo de fuentes oficiales como las instituciones ecuatorianas.

- **Limpieza de datos:** En esta etapa se realiza un tratamiento de los datos que consiste en identificar y manejar valores atípicos, faltantes o inconsistentes.
- **Normalización de datos:** Escalar los datos a un rango adecuado, asegurando uniformidad para el modelado.
- **Construcción del ABT:** Crear la ABT que consolidará todas las variables relevantes para el análisis.

2. EDA.

- **Analizar las características estructurales de las variables:** Evaluar la estructura de las variables para identificar patrones, tendencias, estacionalidad y estacionariedad.
- **Identificar las variables significativas:** Seleccionar las variables descriptivas que tienen una correlación relevante con la tasa de desempleo, garantizando que el modelo utilice los factores más influyentes en su análisis.

3. Modelado.

- **Selección y transformación de características descriptivas:** En caso de requerirse se transforman las variables descriptivas para mejorar la precisión y eficiencia del modelo.
- **División del ABT en subconjuntos de entrenamiento y prueba:** Separar el conjunto de datos en subconjuntos de entrenamiento y prueba para el proceso de aprendizaje.
- **Selección del modelo propuesto y modelos referenciales de IA:** Diseñar e implementar el modelo GA-LSTM y los modelos referenciales BiLSTM y GRU del tipo RNN, para establecer una base de comparación.
- **Entrenamiento de los modelos:** Entrenar el modelo GA-LSTM y los modelos referenciales usando el conjunto de entrenamiento.

4. Evaluación.

- **Evaluación de los modelos:** Comparar el rendimiento del modelo GA-LSTM vs. los modelos referenciales utilizando las métricas de evaluación MSE, MAE, MAPE y la prueba estadística t-pareada.
- **Ajuste de hiperparámetros de los modelos:** Optimizar los hiperparámetros de los modelos para mejorar su rendimiento.
- **Implementación y despliegue:** Integrar el modelo final en el entorno de producción Google Colab para realizar predicciones de la tasa de desempleo.

3.2.1. Recopilación y preprocesamiento de los datos

Parte del conjunto de datos utilizado consiste en datos longitudinales obtenidos del sitio web del Banco Central del Ecuador (BCE), del Instituto Nacional de Estadística y Censos (INEC) y del Ministerio de Trabajo del Ecuador; mientras que otros fueron proporcionados directamente por estos organismos con el fin de unificar la información requerida en esta investigación.

Los datos corresponden a un período de 216 meses, desde enero 2002 hasta diciembre 2019. El conjunto de datos consta de una variable principal y tres variables independientes. La Tabla 2.7. describe las variables utilizadas en este estudio.

Tipo de variable	Nombre de la variable	Código de la variable	Explicación
Variable principal	Tasa de desempleo	Y	La tasa de desempleo es un indicador económico que mide el porcentaje de la población activa que no tiene empleo, pero se encuentran disponibles y tratando de conseguir un empleo. Se obtiene al dividir el número de desempleados entre la población activa total y luego multiplicando por cien. Este índice es vital para medir la salud económica nación, pues revela la cantidad de individuos que están dispuestos y en edad de trabajar, pero no logran conseguir un trabajo.
Variables independientes	Salario mínimo	X1	El salario mínimo es la cantidad mínima de remuneración que un empleador está legalmente obligado a pagar a los trabajadores por el trabajo realizado en un período determinado. El propósito del salario mínimo es proteger a los trabajadores de remuneraciones inadecuadas, garantizando su participación justa en los beneficios del progreso económico y asegurando que

Producto interno bruto (PIB)	X2	reciban un salario mínimo digno. El producto interno bruto es la medida del valor de todos los bienes y servicios finales producidos en un país durante un período específico, ya sea trimestral o anual. Se calcula considerando el valor agregado bruto (VAB), que es la diferencia entre la producción y el consumo intermedio, incluyendo factores como remuneraciones, impuestos y excedente bruto.
Formación bruta de capital fijo (FBCF)	X3	La formación bruta de capital fijo es el aumento en el valor de los activos fijos de un país, empresa o sector económico durante un período determinado, generalmente de un año.

Tabla 2.7. Variables dependientes e independientes utilizadas

La limpieza de datos incluyó un análisis de las variables para tratar los valores faltantes, duplicados y atípicos. En este proceso, se seleccionaron cinco indicadores: tasa de inflación, salario mínimo, PIB, FBCF y tasa de desempleo. Para el caso de los índices del PIB y la FBCF cubrieron el rango de 2000 a 2020, y en el caso de los índices de la tasa de inflación, el salario mínimo y la tasa de desempleo abarcaron el período de 2002 a 2020. Para unificar el rango temporal, se ajustó el período de análisis a 2002-2019, excluyendo el año 2020 por considerarlo como un valor atípico debido al impacto de la pandemia de COVID-19. Además, el salario mínimo fue deflactado con base en el año 2007. No se encontraron valores faltantes ni duplicados en el conjunto de datos. Con respecto a los valores atípicos en las características descriptivas, se utilizó la técnica del rango intercuartílico (IQR) aplicando la regla IQR de 1.5, que designa cualquier valor menor que $Q1 - (1.5 * IQR)$ o mayor que $Q3 + (1.5 * IQR)$ como un valor atípico. Se encontró que las variables del salario mínimo, el PIB y la FBCF no presentan valores atípicos ya que sus valores mínimos y máximos están dentro del rango de los valores umbral inferior y superior para valores atípicos (Tabla 2.8.).

Característica	RIQ	Valor mínimo	Valor máximo	Umbral inferior para valores atípicos	Umbral superior para valores atípicos
Salario mínimo	92.75	160.47	295.42	56.57	427.57
PIB	1,658,039.56	3,354,522	6,027,977.67	1,660,780.82	8,292,939.05
FBCF	546,292.34	659,222	1,597,455	30,574.75	2,215,744.11

Tabla 2.8. Determinación de valores atípicos en las características descriptivas

La normalización de datos se realiza utilizando la clase *StandardScaler* del módulo de preprocesamiento de Scikit-learn, la cual estandariza las características descriptivas eliminando la media y escalándolas a una varianza unitaria. Este proceso asegura que todas las características tengan una influencia equilibrada en el modelo al eliminar las diferencias en las escalas de las variables, lo cual facilita la convergencia durante el entrenamiento y permite al modelo aprender de manera más eficiente. La puntuación estándar de una muestra x se calcula como:

$$z = \frac{x - \mu}{\sigma} \quad (3)$$

Dónde z indica el valor normalizado, x representa el valor real, μ es la media de las muestras de entrenamiento o cero, y σ es la desviación estándar de las muestras de entrenamiento o uno.

La ABT construida contiene características en bruto, no se usaron características derivadas. La inflación, el salario mínimo, el PIB y la FBCF son las variables descriptivas, y la tasa de desempleo la variable objetivo; derivadas desde múltiples fuentes de datos existentes al ABT. La Tabla 2.9. muestra las primeras y las últimas cinco filas de la ABT construida para predecir la tasa de desempleo.

Fecha	Inflación	Salario	PIB	FBCF	Desempleo
01-2002	1.80	160.47	3354522.00	710795.67	9.20
02-2002	1.07	162.18	3361771.52	709123.72	9.37
03-2002	1.13	164.00	3369036.70	707455.70	9.55
04-2002	1.49	166.45	3376317.59	705791.61	9.73
05-2002	0.49	167.27	3383614.21	704131.43	9.91
...
...
08-2019	-0.10	293.39	5959073.10	1374313.35	5.81
09-2019	-0.01	293.35	5954637.20	1374038.10	5.94
10-2019	0.52	294.88	5950204.62	1373762.90	5.59
11-2019	-0.70	292.80	5945775.33	1373487.75	5.26
12-2019	-0.01	292.78	5941349.33	1373212.67	4.95

Tabla 2.9. Conjunto de datos de desempleo en Ecuador (2002-2019)

Fuente: Elaboración propia en base a los datos del Banco Central del Ecuador (BCE), el Instituto Nacional de Estadísticas y Censos (INEC) y el Ministerio del Trabajo del Ecuador.

La tabla 2.10 muestra el rango de valores de las variables del conjunto de datos de desempleo.

Variables	Rango
Inflación	[-0.70,2.48]
Salario	[160.47,295.42]
PIB	[3354522.00,6027977.67]
FBCF	[659222.00 ,1597455.00]
Desempleo	[4.54,11.50]

Tabla 2.10. Rango de variables

Por lo general se requieren múltiples *características* (Apéndice F) para expresar completamente cada *concepto de dominio* único de la *solución de análisis*, por lo que previamente a la construcción de la ABT se realizó un mapeo de variables para definir la relación jerárquica entre estos elementos (Figura 2.16.).

Predicción de la tasa de desempleo	Factores Económicos	Indicadores Económicos Comercio y Ventas	PIB, PIB real, Valor agregado de la industria primaria, Valor agregado de la industria secundaria, Valor agregado de la industria terciaria, Consumo e inversiones a precios constantes y ajustados estacionalmente, Gastos financieros, Inversión en activos fijos, Número de población urbana, Renta disponible de los residentes urbanos, Saldo de los depósitos de ahorro de los residentes urbanos y rurales, Valor agregado de toda la industria de la ciudad, Número de la población, Gastos en políticas activas del mercado laboral, Tasa de inflación, Cambio en la inflación, IPC. Importaciones y exportaciones totales, Ventas minoristas totales de bienes de consumo.
	Factores del Mercado Laboral	Mercado Laboral y Empleo Sindicatos y Coordinación de Empleadores	Tasa de desempleo (ajustada y no ajustada estacionalmente), Número de desempleados, Número de vacantes, Entrada al desempleo registrado, Salida del desempleo al mercado laboral, Estrechez del mercado laboral, Ratio de reemplazo, Duración del beneficio, Expectativas de empleo para los sectores de manufactura y no manufactura, Empleo y desempleo de la Encuesta por muestreo de la fuerza laboral (LFSS). Cobertura sindical, Coordinación sindical, Coordinación de empleadores.
	Factores Sociales y Demográficos	Factores de Renta y Ahorro Población y Demografía	Renta disponible de los residentes urbanos, Saldo de los depósitos de ahorro de los residentes urbanos y rurales. Número de emigrantes, Número de la población total.
	Indicadores de Búsqueda en Línea y de Percepción Pública	Datos de Búsqueda en Línea y Redes Sociales Indicadores de Percepción y Expectativas	Google Trends: Índice de búsqueda de empleo de Google (GJSI), Valores actuales y rezagados de las búsquedas de Google, Índice de Google GI (Google Trends), Sugerencias de búsquedas de Google en distintos idiomas para consultas sobre prestaciones por desempleo y desempleo, Datos sobre la intensidad de actividades de ocio en línea, Artículos de noticias, blogs y tweets. Encuesta de Confianza del Consumidor de EE. UU., Expectativas de empleo en sectores de manufactura y no manufactura (Informe del Institute for Supply Management - ISM), Índice de incertidumbre de la política económica, Datos de consulta en motores de búsqueda: "Local/Jobs" y "Society/Social Services/Welfare & Unemployment".
	Factores Derivados de Estudios y Modelos Estadísticos	Índices Derivados y Variables Agregadas	GoogJSA : Término de búsqueda "JSA" en Google, normalizado semanalmente. GoogRed : Término de búsqueda "Redundancy" en Google, normalizado semanalmente. GRI : Google Redundancy Index, un índice derivado de términos relacionados con despidos. RoJPP : Reporte sobre colocaciones permanentes de empleo (KPMG/REC). RoJTB : Reporte sobre facturación temporal (KPMG/REC). RoJVC : Índice de vacantes en Report on Jobs (KPMG/REC). RoJSA : Índice de disponibilidad de candidatos (KPMG/REC). PMIEM : Índice de empleo del índice de gerentes de compras (PMI) del Reino Unido. ConExp : Expectativas de desempleo según la encuesta de consumidores de DG EcFin. BoESR : Encuesta de intención de empleo en el sector servicios del Banco de Inglaterra. BoEMN : Encuesta de intención de empleo en el sector manufacturero del Banco de Inglaterra. F1 y F2 : Factores derivados de análisis de componentes principales en encuestas y datos de Google.
	Resultado de la tasa de desempleo		

Figura 2.16. Relación jerárquica general entre la solución de análisis, dominios/subdominios y características descriptivas para predecir la tasa de desempleo

Las variables independientes proporcionan información clave sobre los factores económicos y sociales que pueden influir en el comportamiento de esta variable objetivo, por lo que su consideración y tratamiento es importante. Al incluir estas variables, el modelo es capaz de captar patrones y relaciones que permiten realizar predicciones más precisas de la tasa de desempleo. En este sentido, se consideraron los estudios de [122], [123] para determinar las características descriptivas del conjunto de datos a usar en la investigación.

3.2.2. Análisis Exploratorio de los Datos (EDA)

Antes de construir los modelos de predicción, es fundamental llevar a cabo una evaluación preliminar de los datos. La fase EDA permite identificar aspectos básicos de la información, verificar su integridad, analizar la distribución y examinar las relaciones entre variables independientes con la variable dependiente, lo que resulta esencial para elegir el modelo adecuado.

3.2.2.1. Integridad de los datos

No se encontraron problemas de integridad en los datos, por lo que las instancias son consideradas estables. En la Tabla 2.9. se registran un total de 216 muestras. Cada muestra tiene 3 características (factores independientes) y 1 indicador (factor dependiente). Los datos se encuentran integrados y cada muestra es un indicador. Para verificar la integración de los datos, se realiza un análisis visual a través del gráfico de violín (Figura 2.17.) y la prueba de Dickey-Fuller Aumentada. En un gráfico de violín, la señal blanca representa la mediana de la característica. El rango del cuadro muestra el cuartil inferior y el cuartil superior. La línea delgada y negra en cada cuadro representa el intervalo de confianza al 95 por ciento. La forma de cada violín muestra como se distribuyen y qué tan densos son los datos, utilizando el método de Estimación de Densidad de Núcleo (KDE) para calcular esta característica de densidad de la información. En un gráfico de violín, el ancho de cada violín representa la densidad de los datos en distintos rangos de valores. En las zonas más amplias del violín, se percibe una densidad aumentada, lo que señala los puntos donde los datos se concentran con mayor fuerza, y en las áreas más angostas, la densidad disminuye, reflejando lugares donde los datos aparecen de manera menos frecuente.

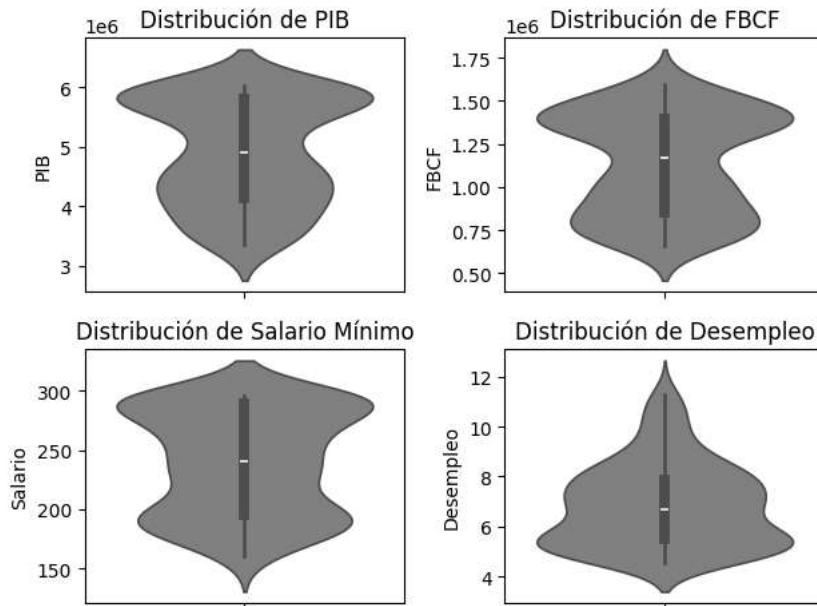


Figura 2.17. Gráficos de violín de las variables

Según la Tabla 2.11. la prueba ADF evalúa la presencia de una raíz unitaria, donde un p-valor alto (generalmente mayor a 0.05) sugiere que la serie no es estacionaria y, por lo tanto, está integrada. Dado que todos los p-valores de las variables son mayores a 0.05, ninguno de estos datos rechaza la hipótesis nula de raíz unitaria, lo que indica que todas las series están integradas y no son estacionarias en sus niveles originales.

Prueba de ADF			
Variable	Dickey-Fuller	Lag order	p-value
Desempleo	-2.9934	5	0.1592
Salario	0.36869	5	0.99
PIB	-0.69125	5	0.97
FBCF	-0.98879	5	0.9382

Tabla 2.11. Prueba de Dickey-Fuller de diferentes variables

3.2.2.2. Características de la distribución de los datos

Dado que las características tienen significados diferentes se analiza por separado el máximo, el mínimo, el promedio, la mediana y otros estadísticos de cada característica para examinar si los datos muestran una distribución asimétrica (Tabla 2.12.); así mismo, se grafica la distribución de cada una de estas variables para visualizar como se agrupan y dispersan los datos (Figura 2.18.).

Estadístico	Salario	PIB	FBCF	Desempleo
Media	239.44	4900602.18	1137321.71	6.85
Desviación estándar	43.89	885785.70	293076.43	1.69
Mínimo	160.47	3354522.00	659222.00	4.54
Cuantil (25%)	195.69	4147840.15	850013.26	5.50
Mediana	240.39	4903242.83	1166555.67	6.68
Cuantil (75%)	288.44	5805879.71	1396305.59	7.89
Máximo	295.42	6027977.67	1597455.00	11.50

Tabla 2.12. Características estadísticas de los datos

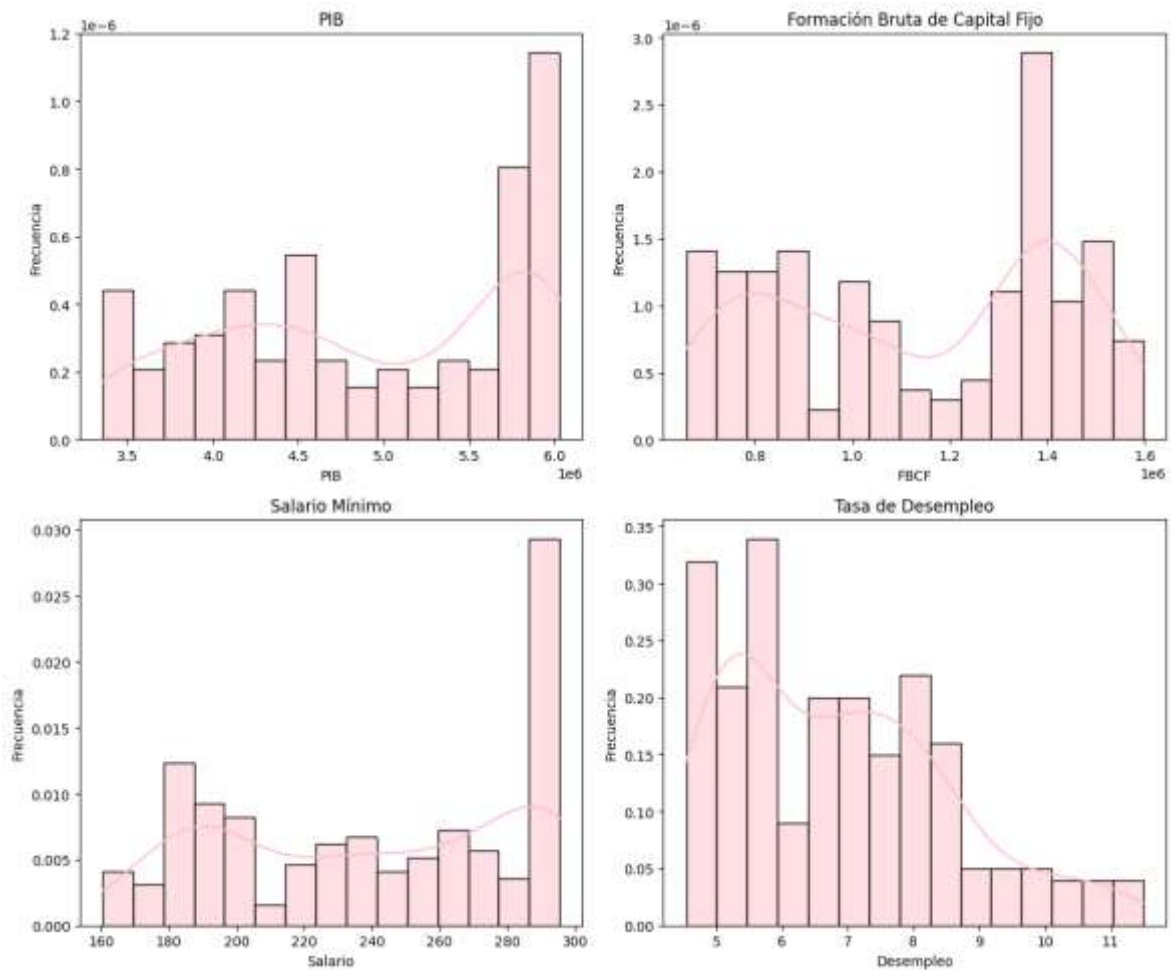


Figura 2.18. Histograma de distribución de diferentes variables

El Coeficiente de Asimetría es un concepto fundamental en estadística que permite analizar y describir la forma de una distribución de datos, indicando si esta presenta una inclinación hacia valores más altos o bajos. La fórmula del Coeficiente de Asimetría es:

$$Sesgo = \frac{\sum(x_i - \bar{x})^3 \cdot f_i}{\sigma^3} \quad (4)$$

Donde: x_i es el i -ésimo dato, f_i es la frecuencia del i -ésimo dato, \bar{x} es la media de la muestra y σ es la desviación estándar de la muestra.

La interpretación del Sesgo se interpreta de la siguiente manera:

- **Simétrica:** Si Sesgo=0.
- **Asimétrica negativa o a la izquierda (o negativamente sesgada):** Si Sesgo<0.
- **Asimétrica positiva o a la derecha (o positivamente sesgada):** Si Sesgo>0.

La Tabla 2.13. presenta los Coeficiente de Asimetría de las variables descriptivas y variable objetivo del desempleo en Ecuador.

Coeficiente de Asimetría	
Variable	Resultado
Desempleo	0.6704
Salario	-0.1414
PIB	-0.2112
FBCF	-0.1524

Tabla 2.13. Coeficiente de Asimetría para diferentes variables

La Figura 2.19. muestra el código desarrollado en R para determinar el Coeficiente de Asimetría de diferentes variables.

```
# Instalar y Cargar el paquete e1071
install.packages("e1071")
library(e1071)
# Leer el archivo CSV (ajusta la ruta y el separador si es necesario)
datos <- read.csv("C:/desempleo.csv", header = TRUE, sep = ";")
# Calcular el coeficiente de asimetría para el Desempleo
asimetria <- skewness(datos$Desempleo)
# Imprimir el resultado
print(paste("Coeficiente de asimetría Desempleo:", asimetria))
# Calcular e imprimir el coeficiente de asimetría para las demás variables
asimetria <- skewness(datos$Salario)
print(paste("Coeficiente de asimetría Salario:", asimetria))
asimetria <- skewness(datos$PIB)
print(paste("Coeficiente de asimetría PIB:", asimetria))
```

Figura 2.19. Código en R para determinar el Coeficiente de Asimetría de diferentes variables

A partir de los resultados obtenidos en las características estadísticas de los datos (Tabla 2.12.), gráficos de histograma (Figura 2.18.) y cálculo del coeficiente de asimetría (Tabla 2.13.), se realizó un análisis de la distribución de las variables del conjunto de datos:

- **Salario:** Con un coeficiente de asimetría de -0.1414 , esta variable presenta una ligera asimetría negativa, lo que indica que la mayoría de los valores se encuentran concentrados en el extremo derecho de la distribución, con una leve cola hacia la izquierda. Esta característica sugiere que la distribución del salario es prácticamente simétrica, con una tendencia marginal hacia los valores superiores.
- **PIB:** El coeficiente de asimetría para el PIB es -0.2112 , también indicando una asimetría negativa ligera. Esta distribución muestra una leve inclinación hacia la izquierda, con una concentración de valores en el extremo derecho. La distribución del PIB puede considerarse casi simétrica, aunque presenta una leve tendencia hacia valores más altos.
- **FBCF:** Con un coeficiente de asimetría de -0.1524 , la FBCF también muestra una asimetría negativa ligera. Esto indica una distribución cercana a la simetría, con una pequeña concentración en el extremo derecho y una cola hacia el lado izquierdo, lo cual sugiere una inclinación leve hacia los valores más altos.
- **Tasa de Desempleo:** El coeficiente de asimetría para la tasa de desempleo es 0.6704 , lo que evidencia una asimetría positiva. En este caso, la mayoría de los valores se encuentran en el extremo izquierdo de la distribución, mientras que existe una cola hacia la derecha. Esta asimetría indica una concentración de valores de desempleo en rangos más bajos, con algunos valores atípicos en los niveles superiores.

Los resultados sugieren que las variables Salario, PIB y FBCF presentan distribuciones que son aproximadamente simétricas, con una leve asimetría negativa. Por otro lado, la Tasa de Desempleo exhibe una asimetría positiva más pronunciada, indicando una mayor concentración de valores en los niveles inferiores y una dispersión hacia valores más altos. Estos patrones en la distribución de las variables deben ser considerados en los análisis posteriores, especialmente en la selección de modelos estadísticos que asuman normalidad o simetría en los datos. Dado que el modelo LSTM no requiere normalidad o simetría y puede manejar estructuras de datos secuenciales y asimétricas, es viable considerarlo para este conjunto de datos.

3.2.2.3. Análisis de correlación

El análisis de correlación se realizó con el propósito de identificar las variables que presentan una relación estadísticamente significativa con la tasa de desempleo, la cual es la variable objetivo de este estudio. Para ello, se empleó el coeficiente de correlación de Pearson, el cual permite medir la relación lineal entre dos variables. Este coeficiente se define como la covarianza entre las variables dividida por el producto de sus desviaciones estándar, proporcionando así un valor que indica la fuerza y dirección de la relación lineal. Se calcula como la covarianza entre dos características, x e y , dividida por el producto de sus desviaciones estándar.

$$r = \frac{\sum(xi - \bar{x})(yi - \bar{y})}{\sqrt{\sum(xi - \bar{x})^2 \sum(yi - \bar{y})^2}} \quad (5)$$

Para medir la relación entre las variables predictoras y la variable objetivo se utilizó el coeficiente de correlación de Pearson (Tabla 2.14.).

Indicador económico	Tasa de desempleo
Tasa de inflación	0.241
Salario mínimo	-0.804*
PIB	-0.863*
Formación Bruta de Capital Fijo	-0.877*

*Coeficientes de correlación estadísticamente significativos en el nivel de significación $\alpha = 0,05$.

Tabla 2.14. Variables significativas

Los resultados del análisis revelaron una correlación estadísticamente significativa entre la tasa de desempleo y las variables salario mínimo, PIB, FBCF, con esta última exhibiendo una relación inversa. Por otro lado, la tasa de inflación no mostró una correlación significativa con la tasa de desempleo, lo que llevó a su exclusión en el modelo de predicción propuesto.

Las variables seleccionadas como predictoras para el modelo son el salario mínimo, el PIB y la GFCF, debido a su relación significativa con la tasa de desempleo (Figura 2.20.). La exclusión de la tasa de inflación, basada en la falta de correlación, asegura que el modelo se enfoque en aquellos indicadores económicos que tienen una influencia demostrada en la variable objetivo. Esta selección de variables contribuye a mejorar la precisión y la relevancia del modelo predictivo en el contexto del análisis económico de la tasa de desempleo.




Figura 2.20 Mapa de calor de la tasa de desempleo vs. inflación, salario mínimo, PIB y FBCF

3.2.3. Modelado y evaluación

Elegir y seleccionar las características descriptivas es fundamental en el proceso de creación del modelado ya que garantiza que los datos de entrada influyen significativamente en la precisión predictiva. Para la predicción de la tasa de desempleo, se han escogido datos económicos importantes como el sueldo mínimo, el Producto Interno Bruto y la Formación Bruta de Capital Fijo, los cuales están relacionados significativamente con el desempleo. Estas variables significativas fueron identificadas en la fase previa de EDA mediante la utilización del coeficiente de correlación de Pearson, que reveló relaciones negativas con la tasa de desempleo. Esto sugiere que aumentos de dichas variables descriptivas se asocia con una disminución en la tasa de desempleo, lo cual justifica su inclusión en las predicciones del modelo híbrido GA-LSTM y RNNs referenciales. Con el fin de facilitar el aprendizaje y la convergencia de los algoritmos utilizados, se estandarizaron los datos del conjunto de datos de desempleo para que todas las variables tengan una escala uniforme y se reduzcan las diferencias en sus magnitudes.

En la siguiente etapa del modelado, se procede a dividir el ABT en grupos de datos. En el caso del modelo GA-LSTM, se opta por una distribución del 80% para entrenamiento, 10% para validación y 10% para prueba. Esta estrategia garantiza una validación efectiva y asegura la existencia de un conjunto de prueba independiente para evaluar el desempeño final del modelo. En cuanto a los modelos BiLSTM y GRU de referencia, se emplea una división porcentual diferente de 90:10 para el entrenamiento y la prueba. Este particionamiento horizontal por fragmentación asegura la generalización en los datos de prueba y permite una evaluación coherente con el enfoque híbrido propuesto.

Para la elección del modelo, se decidió utilizar un método combinado llamado GA-LSTM, que fusiona la capacidad de capturas de dependencias en la data a largo plazo de las redes neuronales LSTM con la eficacia y potencia de los GA en ajustar los hiperparámetros del modelo. Dicho de otra forma, la red LSTM es una estructura de red neuronal recurrente creada para detectar y capturar patrones secuenciales y no lineales en series temporales, a la vez que el GA se emplea para mejorar los parámetros esenciales de la red, maximizando su rendimiento predictivo. Este nuevo método GA-LSTM se compara con modelos convencionales como el BiLSTM y GRU, que son reconocidos por ser eficaces en la predicción de patrones en secuencias temporales; de esta manera se realiza un benchmarking de modelos cuyo objeto es medir el rendimiento del modelo propuesto en términos de precisión vs. los modelos individuales referenciales.

En la última etapa de entrenamiento, GA se emplea para mejorar aspectos importantes de la red neuronal LSTM, como el tamaño de ventana temporal y la cantidad de unidades LSTM, con el objetivo de aumentar la capacidad de predicción del modelo. Este procedimiento de optimización asegura que la arquitectura de la red LSTM está óptimamente configurada, lo que facilita la adaptación del modelo a los patrones secuenciales y complejos presentes en los datos de desempleo mejorando así la precisión de la predicción de la serie de desempleo ecuatoriana.

Se evalúan los modelos utilizando diferentes medidas de precisión: MSE, MAE y MAPE. Estas métricas ofrecen una forma de cuantificar la precisión de las predicciones, lo que facilita la comparación del desempeño del modelo GA-LSTM con los modelos referenciales. El uso de estas medidas facilita el análisis e interpretación de que modelo presenta la mayor precisión de predicción en la tasa de desempleo.

La optimización de los hiperparámetros en el modelo híbrido se efectúa automáticamente mediante GA, el cual optimiza los hiperparámetros clave de tamaño de la ventana y el número de unidades de la red LSTM. Este proceso es iterativo y posibilita explorar, seleccionar varias configuraciones que maximizan la capacidad predictiva del modelo, evitando realizar ajustes manuales que demandan de tiempo y experiencia de parte del científico de datos. En lo concerniente al ajuste de hiperparámetros de los modelos referenciales, se utilizó la técnica GridSearchCV de la biblioteca Scikit-learn. Esta técnica se configuró de la siguiente manera: el número de capas ocultas se definió como (1, 2), el número de unidades ocultas como (2, 3, 4, 5, 6, 7, 8), el tamaño del lote como (2, 4, 8, 10, 12, 14), el número de épocas como (32, 34, 36, 60, 65, 70, 75, 80) y los optimizadores considerados fueron (RMSprop, Adam).

Finalmente, una vez completadas las fases de entrenamiento y la evaluación, el modelo GA-LSTM optimizado se implementa y despliega en la nube utilizando las herramientas Colab y Ngrok.

El modelado y evaluación de los modelos de IC se discuten con mayor detalle en el apartado 4 de Experimentación.

3.2.3.1. Aplicación del algoritmo híbrido GA-LSTM

La combinación híbrida GA-LSTM combina la capacidad de optimización del GA con las ventajas de las redes LSTM para predecir el desempleo en Ecuador. Su propósito radica en optimizar los hiperparámetros clave de ventana de tiempo y unidades ocultas del modelo LSTM a través de un procedimiento iterativo evolutivo GA que busca minimizar el RMSE del modelo.

La red neuronal LSTM posibilita el proceso secuencial de la data a través de una estructura compuesta por una capa de entrada secuencial, una capa LSTM y una capa de salida densa. Las unidades LSTM tienen un diseño que consta de una celda de memoria y tres compuertas distintas: una para recibir datos nuevos, otra para olvidar información anterior y la tercera para obtener la salida. Estas puertas permiten capturar dependencias a largo plazo y realizar ajustes rápidos para adaptarse a corto plazo para recordar y gestionar eficazmente información importante a lo largo del tiempo. En la arquitectura se usan dos funciones, la función de activación de tangente hiperbólica se emplea para las entradas y los nodos LSTM mientras que la capa de salida utiliza una función lineal la cual es adecuada para problemas de regresión. Los valores iniciales de los pesos en la red se eligen al azar y su ajuste es a través del método de optimización Adam, lo que acelera el proceso de convergencia durante el entrenamiento.

El proceso de implementación inicia importando las bibliotecas esenciales como NumPy, Pandas y Scikit-learn adecuadas para manejar y escalar los datos; Keras para diseñar y enseñar la red neuronal LSTM; DEAP útil para construir y llevar a cabo el proceso de ejecución del método evolutivo GA; y Matplotlib para mostrar los resultados de la predicción.

La información económica del desempleo se organiza mediante la segmentación de los datos en ventanas de longitud específica las cuales actúan como datos de entrada y salida en el modelo. Estos conjuntos de datos son escalados normalizando las características aportando a la mejora de la eficiencia y consistencia del proceso de aprendizaje del modelo RNN LSM.

Para representar los hiperparámetros en el GA se utiliza una codificación binaria: el tamaño de la ventana se codifica con 5 bits y que el número de unidades LSTM se representa con 4 bits. Esta representación compacta binaria facilita la manipulación genética durante las etapas de evolución, como la selección, cruce y mutación.

GA se configura para explorar un espacio de soluciones posibles en donde cada población contiene 4 individuos que evolucionan durante 10 generaciones, y cada individuo es la configuración binaria de 9 cromosomas. A cada individuo se le analiza su aptitud usando la función RMSE, procesando su desempeño con parámetros específicos aleatorios usando una distribución de Bernoulli equitativa de 0.5 en el modelo LSTM creado. Los operadores de cruce y mutación mejoran aún más estas soluciones durante las generaciones, mientras que el proceso de selección de ruleta asegura la convergencia hacia configuraciones óptimas. El ajuste de hiperparámetros de los modelos neuronales es importante porque optimiza el proceso de aprendizaje [115].

Una vez que se determina la combinación ideal de hiperparámetros, se procede a entrenar el modelo LSTM con estos parámetros óptimos. Durante este proceso de entrenamiento, se utilizan técnicas de validación cruzada para garantizar que el modelo no se ajuste demasiado y se evalúa el rendimiento del modelo final en un set de datos de prueba separado. Las predicciones realizadas se confrontan con los datos reales con el fin de determinar el índice de desempeño RMSE, evaluando la exactitud del modelo. A su vez, se representan los resultados mediante gráficos de curvas de pérdida en el proceso de entrenamiento y validación, y una comparativa entre las estimaciones y los datos reales.

Finalmente, el modelo GA-LSTM se compara con enfoques alternativos BiLSTM y GRU, utilizando las métricas de rendimiento MSE, MAE y MAPE, demostrando mejoras significativas en la precisión predictiva gracias a la optimización de hiperparámetros de LSTM mediante los GA.

El proceso específico de implementación del algoritmo GA-LSTM sigue los pasos descritos a continuación:

1. **Importación de librerías y módulos:** Se importan las bibliotecas requeridas para el proceso de predicción, que incluyen: *NumPy*, *Pandas* y *Scikit-learn* para la manipulación de datos; *Matplotlib* para la visualización de datos; *Keras* para la implementación de redes neuronales; *Pyngrok* para crear túneles hacia un servidor local y *DEAP*, *Bitstring* y *SciPy* para la implementación de algoritmos genéticos, manipulación de las estructuras de los cromosomas y generación de valores binarios aleatorios mediante la distribución de Bernoulli, respectivamente.
2. **Importación del conjunto de datos:** Se importa el conjunto de datos “desempleo.csv” para entrenar y evaluar el modelo desde un repositorio de GitHub.
3. **Preparación del conjunto de datos (prepare_dataset):** Se preparan las secuencias de datos para el modelo LSTM, dividiendo la serie de tiempo de desempleo escalada en ventanas de una longitud específica en donde cada ventana representa un conjunto de entrada y salida utilizada como input para la red neuronal recurrente.
4. **Definición de la función de entrenamiento y evaluación (train_evaluate):** Esta función crea la red LSTM para un individuo determinado y devuelve la precisión del entrenamiento utilizando la métrica de RMSE en un conjunto de validación, devolviendo este valor como medida de aptitud del individuo.
5. **Definición de la estructura del algoritmo genético:** Utilizando la biblioteca DEAP, se configura el algoritmo genético, especificando las características de los individuos, población inicial aleatoria y los operadores genéticos de cruce, mutación y selección. La Tabla 2.15. muestra los parámetros del modelo GA.

Parámetros del modelo GA	
Nombre del parámetro	Valor del parámetro
Tamaño del cromosoma	9
Tamaño de la población	4
Tasa de cruce	0.6
Tasa de mutación	0.4
Número de generaciones	10

Tabla 2.15. Parámetros del modelo GA

6. **Ejecución del algoritmo genético:** El algoritmo genético evoluciona la población de individuos durante varias generaciones. Durante cada generación, los individuos se cruzan, mutan y son seleccionados en función de su aptitud según su aptitud medida por RMSE. Este ciclo es iterativo hasta llegar al máximo de generaciones o cuando se satisfaga un criterio de convergencia.
7. **Selección del mejor individuo:** GA devuelve el individuo con la mejor aptitud, este individuo óptimo es seleccionado y almacenado en las variables que representan a la mejor ventana y unidad (*best_window_size* y *best_num_units*).
8. **Construcción y entrenamiento del modelo LSTM con los parámetros óptimos:** Se utiliza la mejor combinación de hiperparámetros para construir un modelo LSTM. El modelo se entrena nuevamente, pero ahora con el conjunto completo de datos de entrenamiento utilizando validación cruzada (10% de los datos de entrenamiento se reservan para validación). Este proceso permite monitorear el desempeño en datos no vistos y ajustar los hiperparámetros de manera efectiva, evitando el sobreajuste. La Tabla 2.16. muestra los parámetros óptimos del modelo LSTM.

Parámetros óptimos del modelo LSTM	
Nombre del parámetro	Valor del parámetro
Unidades ocultas	12
Tamaño de la ventana	3

Tabla 2.16. Parámetros óptimos del modelo LSTM

9. **Evaluación del modelo en el conjunto de prueba:** El modelo entrenado con los parámetros óptimos se evalúa en el conjunto de datos de prueba. Las predicciones del modelo en el conjunto de prueba se comparan con los valores reales de la serie temporal para calcular la precisión del modelo. La Tabla 2.17. muestra la configuración técnica del modelo GA-LSTM.

Configuración técnica óptima del modelo GA-LSTM	
Nombre del parámetro	Valor del parámetro
Capas de red	3
Tamaño de capa oculta	12
Tamaño del lote	10
Tamaño de la ventana	3
Función de pérdida	MSE
Función de activación	Lineal
Épocas de optimización	5
Optimizador	Adam
Entrenamiento:validación:prueba	8:1:1

Tabla 2.17. Configuración técnica del modelo GA-LSTM

10. **Visualización de resultados:** Se grafican los resultados del modelo, mostrando las curvas de pérdida para el conjunto de entrenamiento y el conjunto de validación a lo largo de las épocas. Además, se grafica la comparación entre los valores reales y las predicciones del modelo, evaluando visualmente la precisión de las predicciones.

El algoritmo híbrido GA-LSTM y estadísticos implementados se encuentran disponible en: <https://github.com/kevinmero/DoctoralThesis>. La tabla 2.18. muestra la implementación del algoritmo GA-LSTM en Python.

Algoritmo	Predicción
Input:	Características: salario mínimo nacional, Producto Interno Bruto (PIB) y Formación Bruta de Capital Fijo (FBCF)
Output:	Valor objetivo: tasa de desempleo
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29	<pre> def import_data(file_path): df = pd.read_csv(file_path, sep='\t', encoding='latin1') cols = df.columns[2:6] return df[cols] def prepare_dataset(data, window_size, num_features): if window_size <= 0: print("Invalid value for window size:", window_size) return np.array([]), np.array([]) # Return empty arrays X, Y = [], [] n_future = 1 for i in range(window_size, len(data) - n_future + 1): X.append(data[i - window_size:i, :num_features]) Y.append(data[i + n_future - 1:i + n_future, 3]) return np.array(X), np.array(Y) def train_evaluate(individual, data): window_size_bits = BitArray(individual[:5]) num_units_bits = BitArray(individual[5:]) window_size = window_size_bits.uint num_units = num_units_bits.uint print("\nWindow Size:', window_size, ', Num of Units:', num_units) if window_size == 0: print("Invalid value for window size:", window_size) window_size = 1 if num_units <= 0: print("Invalid value for number of units, setting to default:", num_units) num_units = 1 X, Y = prepare_dataset(data, window_size, 4) if len(X) == 0 or len(Y) == 0: return 100.0, # Return a high error value if the data is invalid </pre>

```
30 X_train, X_val, y_train, y_val = train_test_split(X, Y, test_size=0.10, random_state=1120)
31 inputs = Input(shape=(window_size, 4))
31 x = LSTM(num_units, input_shape=(window_size, 4))(inputs)
33 predictions = Dense(1, activation='linear')(x)
34 model = Model(inputs=inputs, outputs=predictions)
35 print(model.summary())
36 model.compile(optimizer='adam', loss='mean_squared_error')
37 model.fit(X_train, y_train, epochs=5, batch_size=10, shuffle=True)
38 y_pred = model.predict(X_val)
39 rmse = np.sqrt(mean_squared_error(y_val, y_pred))
40 print('Validation RMSE:', rmse, '\n')
41 return rmse,
42 def define_individuals_and_population(population_size, gene_length, train_data):
43     creator.create('FitnessMax', base.Fitness, weights=(-1.0,))
44     creator.create('Individual', list, fitness=creator.FitnessMax)
45     toolbox = base.Toolbox()
46     toolbox.register('binary', bernoulli.rvs, 0.5)
47     toolbox.register('individual', tools.initRepeat, creator.Individual, toolbox.binary, n=gene_length)
48     toolbox.register('population', tools.initRepeat, list, toolbox.individual)
49     toolbox.register('mate', tools.cxOrdered)
50     toolbox.register('mutate', tools.mutShuffleIndexes, indpb=0.6)
51     toolbox.register('select', tools.selRoulette)
52     toolbox.register('evaluate', train_evaluate, data=train_data)
53     return toolbox.population(n=population_size), toolbox
54 def run_genetic_algorithm(population, toolbox, num_generations):
55     return algorithms.eaSimple(population, toolbox, cxpb=0.6, mutpb=0.4, ngen=num_generations, verbose=False)
56 def get_best_solution(population):
57     best_individual = tools.selBest(population, k=1)[0]
58     window_size_bits = BitArray(best_individual[:5])
59     num_units_bits = BitArray(best_individual[5:])
60     best_window_size = window_size_bits.uint
61     best_num_units = num_units_bits.uint
62     return best_window_size, best_num_units
```

```

63     def implement_best_solution(train_data, test_data, best_window_size, best_num_units, scaler):
64         if best_window_size <= 0:
65             print("Invalid value for window size:", best_window_size)
66             return np.array([]), np.array([]), {}
67         num_features = 4
68         X_train, y_train = prepare_dataset(train_data, best_window_size, num_features)
69         X_test, y_test = prepare_dataset(test_data, best_window_size, num_features)
70         inputs = Input(shape=(best_window_size, num_features))
71         x = LSTM(best_num_units, input_shape=(best_window_size, num_features))(inputs)
72         predictions = Dense(1, activation='linear')(x)
73         model = Model(inputs=inputs, outputs=predictions)
74         model.compile(optimizer='adam', loss='mean_squared_error')
75         history = model.fit(X_train, y_train, epochs=5, batch_size=10, validation_split=0.1, verbose=1, shuffle=True)
76         y_pred = model.predict(X_test)
77         rmse = np.sqrt(mean_squared_error(y_test, y_pred))
78         y_test_real = scaler.inverse_transform(np.concatenate((np.zeros((y_test.shape[0], 3)), y_test), axis=1))[:, 3]
79         y_pred_real = scaler.inverse_transform(np.concatenate((np.zeros((y_pred.shape[0], 3)), y_pred), axis=1))[:, 3]
80         return y_test_real, y_pred_real, history.history
81     def setup_ngrok(n_port):
82         token = " your ngrok token" #set a default authentication token
83         ngrok.set_auth_token(token)
84         public_url = ngrok.connect(n_port)
85         print("Public URL:", public_url)
86         input("Press Enter to open the ngrok URL...")
87         return public_url
88     def MyModel():
89         global train_data
90         np.random.seed(1120)
91         public_url = setup_ngrok(5000)
92         file_path = 'https://raw.githubusercontent.com/kevinmero/Unemployment-rate-prediction/main/data/desempleo.csv'
93         df_train = import_data(file_path)
94         train_data, test_data = train_test_split(df_train, test_size=0.10, random_state=42, shuffle=False)
95         scaler = StandardScaler()

```

```
96     train_data_scaled = scaler.fit_transform(train_data)
97     population_size = 4
98     num_generations = 4
99     gene_length = 9
100    population, toolbox = define_individuals_and_population(population_size, gene_length, train_data_scaled)
101    run_genetic_algorithm(population, toolbox, num_generations)
102    best_window_size, best_num_units = get_best_solution(population)
103    test_data_scaled = scaler.transform(test_data)
104    real_values, predicted_values, history = implement_best_solution(train_data_scaled, test_data_scaled, best_window_size,
105    best_num_units, scaler)
106    plt.plot(history['loss'], label='Training loss')
107    plt.plot(history['val_loss'], label='Validation loss')
108    plt.legend()
109    plt.title('Training and validation loss')
110    plt.ylabel('Loss')
111    plt.xlabel('Epoch')
112    plt.show()
113    print("\n\n")
114    print("Real Values:", real_values)
115    print("Predicted Values:", predicted_values)
116    print("Best Window Size:", best_window_size)
117    print("Best Num of Units:", best_num_units)
118    MyModel()
119    end prediction
```

Tabla 2.18. Algoritmo híbrido GA-LSTM

3.3. Comparación de enfoques

En el presente estudio, se seleccionaron los modelos BiLSTM y GRU como referencias para comparar el rendimiento del modelo híbrido propuesto GA-LSTM. Ambos modelos son variantes de redes neuronales recurrentes ampliamente utilizadas en la predicción de series temporales por su capacidad de manejar dependencias en secuencias de datos.

- **Motivación de la selección de modelos:** La selección de BiLSTM y GRU se basa en su efectividad comprobada en capturar patrones temporales en datos económicos. El modelo BiLSTM permite una mayor precisión al procesar la información de los pasos de tiempo en direcciones hacia adelante y hacia atrás simultáneamente, lo cual es particularmente útil para identificar tendencias en la tasa de desempleo al gestionar eficazmente el problema del gradiente evanescente y capturar dependencias a largo plazo. Por otro lado, GRU es menos complejo que el modelo LSTM ya que ofrece una arquitectura simplificada con dos compuertas (actualizar y reiniciar) que gestionan el estado oculto de la red a medida que procesa secuencias facilitando de esta manera el entrenamiento GRU.
- **Ventajas comparativas del modelo GA-LSTM:** El modelo GA-LSTM integra GA para la optimización de hiperparámetros del LSTM, permitiendo ajustar de manera precisa el tamaño de la ventana temporal y el número de unidades de LSTM. Esto mejora la capacidad de predicción y supera las limitaciones de los modelos BiLSTM y GRU, que no cuentan con este mecanismo de optimización interna. La combinación de las propiedades de LSTM con el poder de optimización del algoritmo genético convierte al GA-LSTM en una solución robusta para abordar la complejidad no lineal inherente en la predicción de la tasa de desempleo en Ecuador.

EXPERIMENTACIÓN

Este capítulo presenta los resultados de las pruebas experimentales realizadas para validar el modelo propuesto. Se detalla la configuración del entorno experimental, el proceso de entrenamiento/evaluación del modelo híbrido y las comparaciones realizadas con los enfoques predictivos BiLSTM y GRU. Se analizan las métricas de desempeño obtenidas lo que conlleva a discutir la efectividad del modelo GA-LSTM en la predicción de la tasa de desempleo; asimismo, se retacan los hallazgos más relevantes y posibles aplicaciones en futuras líneas de investigación.

4.1. Fase experimental

4.1.1. Configuración del entorno de desarrollo

En esta tesis, todos los experimentos se llevaron a cabo en un equipo portátil con características de un procesador i7 (2.20 GHz, 9 MB de caché), 16 GB de RAM, HDD de 512 GB y un sistema operativo Windows 10. En la implementación de los modelos se utilizó el lenguaje de programación Python (versión 3.8.16), mediante las bibliotecas de aprendizaje profundo Keras (versión 2.9.0), TensorFlow (versión 2.9.2), NumPy (versión 1.21.6), Pandas (versión 1.3.5) y Matplotlib (versión 3.2.2) para el procesamiento, manipulación y visualización de datos. También se usaron los paquetes Deap (versión 1.3.3) y Bitstring (versión 4.0.1) como marco de computación evolutiva y para la gestión de los cromosomas binarios.

El diseño del modelo GA-LSTM utilizó indicadores económicos clave como el PIB, el salario mínimo y la formación bruta de capital fijo como variables de entrada para predecir el desempleo en Ecuador en un periodo de diecinueve meses. Durante el proceso de aprendizaje, el modelo híbrido capturó las tendencias del desempleo en Ecuador gracias a la optimización de sus parámetros mediante GA logrando maximizar la precisión en el horizonte temporal continuo de junio de 2018 hasta diciembre de 2019 demostrando su capacidad para ajustarse a las dinámicas complejas presentadas en dicho período.

Aunque la configuración del ambiente resultó técnicamente adecuada para la mayoría de los experimentos, se encontraron limitaciones significativas en términos de rendimiento computacional al ejecutar los algoritmos individuales optimizados con la técnica GridSearchCV. Este método fue diseñado para explorar sistemática y exhaustivamente todas las combinaciones posibles de hiperparámetros definidos en los modelos de IA, cuyos tiempos de ejecución fueron elevados con un tiempo promedio superior de 20 minutos por cada ejecución que retorna la mejor configuración de parámetros del modelo de aprendizaje automático evaluado. Este comportamiento se debe a la complejidad que subyace en los modelos de IA y al elevado número de combinaciones de hiperparámetros que comprueba la técnica de validación cruzada para seleccionar los hiperparámetros óptimos.

El equipo portátil descrito fue suficiente para las tareas de procesamiento y entrenamiento del modelo híbrido GA-LSTM, su implementación aprovechó los recursos robustos del servicio en la nube de Google Colab free. Sin embargo, los algoritmos referenciales enfrentaron restricciones significativas debido a las limitaciones técnicas, de disponibilidad y de tiempo de uso de CPU, GPU, TPU y RAM de Colab free; por lo que dichos algoritmos requieren mayor capacidad de cómputo de las unidades de procesamiento que permitan acelerar el entrenamiento y evaluación de los modelos de aprendizajes durante sesiones largas y sin desconexión alguna de la herramienta Colab.

Google evalúa factores como el uso reciente y la disponibilidad de recursos para determinar el tiempo de uso permitido en Colab free, el acceso a recursos como las GPU es limitado, con un tiempo máximo de ejecución de los notebooks de 12 horas por sesión¹⁹. Debido a las pruebas exhaustivas realizadas a los algoritmos, los límites de uso resultaron ser dinámicos, variando según la frecuencia y duración del uso de la plataforma Colab en la nube; debido a dichas limitaciones técnicas los modelos referenciales se migraron a la herramienta Anaconda 2.6.0. para ejecutar los experimentos. Por restricciones presupuestarias, no se realizaron pruebas con un plan premium (Colab Pro o Pro+), que ofrece mayor disponibilidad, capacidad y prioridad en el acceso a recursos.

Otro factor limitante de hardware es el uso del HDD de la portátil, que limitó aún más la velocidad de acceso a los datos durante las operaciones intensivas realizadas por GridSearchCV en los modelos referenciales, dichas restricciones impactan en la eficiencia general de los experimentos.

¹⁹ <https://research.google.com/colaboratory/faq.html>

El modelo híbrido GA-LSTM no presentó mayores inconvenientes al ser implementado y soportado en un entorno computacional en la nube más avanzado, los algoritmos referenciales evidenciaron limitaciones significativas en términos de tiempo y recursos al ejecutarse tanto en Colab free como en el entorno local.

4.1.2. Proceso de entrenamiento y prueba

El proceso inició separando los datos en diferentes grupos para entrenamiento, validación y prueba según una estructura diferenciada para cada modelo. En el modelo GA-LSTM, se asignó un 80% de los datos para entrenar, un 10% para validar y otro 10% para test lo que permite al modelo híbrido aprender los patrones del desempleo y una validación intermedia para verificar su precisión antes de la fase de prueba final. En lo que respecta a los modelos BiLSTM y GRU se dividió el conjunto de datos en un 90% para entrenamiento y un 10% para prueba, ya que estos modelos no necesitan una validación intermedia.

Esta estructura diferenciada permite una evaluación adecuada del rendimiento de cada modelo y facilita la predicción de los últimos 22 meses de la tasa de desempleo para BiLSTM y GRU, y de los últimos 19 meses en el caso de GA-LSTM, considerando una ventana de tiempo de tamaño 3 (Tabla 2.19.).

No.	Dataset	No. De atributos	Modelo	No. de muestras de entrenamiento	No. de muestras de validación	No. de muestras de prueba
1	Desempleo	4	GA-LSTM	172	22	22 (de estas muestras se predicen 19 debido a la configuración de la ventana temporal en el modelo híbrido)
			BiLSTM, GRU	194	-	22

Tabla 2.19. Distribución de muestras para la regresión de la tasa de desempleo según el modelo utilizado

Previo al entrenamiento, los datos de entrada del modelo propuesto fueron normalizados utilizando la clase StandardScaler de Scikit-learn, eliminando la media y escalando a una varianza unitaria para garantizar que todas las características contribuyan equilibradamente al aprendizaje del modelo. Posteriormente, se entrenó el modelo GA-LSTM optimizando sus parámetros mediante algoritmos

genéticos, ajustando el tamaño de la ventana de tiempo y el número de unidades LSTM para capturar eficazmente las dependencias temporales en las variables económicas. La optimización Adam se usó para ajustar los pesos del modelo, esta técnica fue adaptativa y eficiente para el problema de predicción de la tasa de desempleo. Para abordar la complejidad no lineal, se empleó la función de activación de tangente hiperbólica (tanh) en las capas ocultas, y para lograr la predicción continua la función de activación lineal en la capa output.

Una vez finalizado el entrenamiento, el modelo híbrido fue sometido a pruebas con un lote de datos para anticipar la fluctuación del índice de desempleo. La información estadística abarcó los diecinueve meses finales de la observación (junio '18 - diciembre '19), empleados para ajustar el modelo a los patrones de desempleo en el contexto ecuatoriano, tomando en cuenta índices claves como el PIB, salario mínimo y FBCF. Para medir qué tan bien funcionaba el modelo, se utilizaron algunas medidas de evaluación, específicamente MSE, MAE y MAPE en los datos de prueba lo que permitió verificar la exactitud del modelo híbrido al predecir la tasa de desempleo. Por último, los parámetros ajustados de tamaño de ventana de 12 y unidades ocultas de 3, obtuvieron valores óptimos de MSE de 0.052, MAE de 0.2 y MAPE de 3.797%, los cuales describen brevemente la configuración y rendimiento final del modelo GA-LSTM.

Más allá del esfuerzo requerido para que el entrenamiento y las pruebas funcionaran bien, encontramos limitaciones importantes que podrían afectar los resultados. Una limitación fue la división diferenciada de los datos. El modelo GA-LSTM usó el 80% para entrenar, el 10% para validación y otro 10% para test. Pero los otros modelos, como BiLSTM y GRU, usaron el 90% para entrenar y solo el 10% para probar, sin la validación intermedia. Un análisis minucioso de esta diferencia en separar los datos de desempleo permitiría conocer si se introduce o no sesgos en la predicción. Además, el entrenamiento de los modelos referenciales resultó ser significativamente más lento y con menos recursos computacionales como la empleada en el modelo híbrido GA-LSTM, lo que aumentó los tiempos de configuración y ejecución. Otra limitación clave fue el entorno computacional local utilizado con procesador i7, 16 GB de RAM y almacenamiento de 512 GB HDD, características que se mostraron insuficientes para manejar de manera eficiente las complejidades de los modelos referenciales, en contraste con el modelo híbrido entrenado en el entorno avanzado Google Colab free.

Por último, aunque los resultados son prometedores, el período de prueba (de junio de 2018 a diciembre de 2019) puede no capturar completamente el comportamiento de los datos en diferentes contextos económicos, lo que limita la extrapolación de los hallazgos a otros escenarios.

4.1.3. Evaluación del desempeño

La evaluación del desempeño del modelo propuesto en esta tesis doctoral, el GA-LSTM, se realizó mediante la comparación de métricas de error con otros modelos, como BiLSTM y GRU. La evaluación incluyó el uso de métricas estándar, como el MSE, MAE y MAPE. Los resultados demostraron que el modelo híbrido GA-LSTM superó a los otros modelos en términos de precisión en la predicción de la tasa de desempleo en Ecuador, lo cual resalta la eficacia de la combinación del poder predictivo de la red LSTM con la capacidad de optimización del algoritmo genético.

El **MSE** mide el promedio de las diferencias al cuadrado entre los valores observados y los valores predichos, lo que ayuda a identificar la dispersión de los errores al elevar las diferencias al cuadrado, resaltando los errores grandes. La fórmula es:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6)$$

Donde el error residual es igual a $(y_i - \hat{y}_i)$, y_i es la salida actual, \hat{y}_i es la salida predicha y n es el número de predicciones.

El **MAE** calcula el promedio de las diferencias absolutas entre los valores reales y los valores estimados, ofreciendo una visión de la precisión general del modelo al enfocarse en la desviación absoluta sin considerar el signo. La fórmula es:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

Donde el error residual es igual a $(y_i - \hat{y}_i)$, y_i es la salida actual, \hat{y}_i es la salida predicha y n es el número de predicciones.

El **MAPE** calcula el promedio de las diferencias porcentuales entre los valores observados y los predichos, expresando el error en términos de porcentaje para facilitar la interpretación relativa del error en distintos contextos. La fórmula es:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (8)$$

Donde el error residual es igual a $(y_i - \hat{y}_i)$, y_i es la salida actual, \hat{y}_i es la salida predicha y n es el número de predicciones.

La **prueba t pareada** es una técnica estadística para determinar si el promedio de las diferencias entre dos modelos de predicción emparejados es significativamente diferente de cero. La fórmula de la prueba t pareada es la siguiente:

$$t = \frac{\bar{d} - 0}{S_{\bar{d}} / \sqrt{n}} \quad (9)$$

Donde \bar{d} es la diferencia media observada, $S_{\bar{d}}$ es el error estándar de la diferencia media observada y n es el número de diferencias.

4.2. Resumen de la fase experimental

La fase experimental de esta investigación se realizó en un equipo portátil con especificaciones adecuadas y utilizando Python y bibliotecas como Keras y TensorFlow para implementar los modelos. El modelo GA-LSTM, desarrollado para predecir la tasa de desempleo en Ecuador, se entrenó con un 80% de los datos, validando un 10% y reservando el 10% restante para pruebas. Otros modelos comparativos, como BiLSTM y GRU, se entrenaron con un 90% de los datos y probaron con el 10% final. Previo al entrenamiento, los datos se normalizaron para mejorar el rendimiento del modelo propuesto y modelos referenciales.

Durante el entrenamiento del GA-LSTM, se optimizaron los hiperparámetros utilizando algoritmos genéticos, enfocándose en ajustar el tamaño de la ventana de tiempo y las unidades LSTM para capturar las dependencias temporales en variables como PIB, salario mínimo y formación bruta de capital fijo. El rendimiento del modelo se evaluó en términos de MSE, MAE y MAPE, logrando un MSE de 0.052, un MAE de 0.200 y un MAPE de 3.797%. Los resultados finales demostraron que el GA-LSTM superó en precisión a los modelos de referencia, destacando la efectividad de combinar LSTM con optimización genética en la predicción económica.

4.3. Resultados

El estudio evaluó varios modelos de redes neuronales recurrentes para predecir la tasa de desempleo en Ecuador, incluyendo los modelos BiLSTM, GRU y el modelo híbrido GA-LSTM, que combina un algoritmo genético con una red LSTM.

Los resultados indican que el modelo GA-LSTM tuvo el mejor rendimiento en términos de MSE, MAE y MAPE, comparado con los modelos BiLSTM y GRU. Los valores de estos indicadores para GA-LSTM fueron significativamente más bajos (MSE: 0.052, MAE: 0.200, MAPE: 3.797%), lo que sugiere una mayor precisión en las predicciones del modelo híbrido. En comparación, el GRU y el BiLSTM presentaron resultados menos precisos, con valores de MSE de 0.072 y 0.130, respectivamente (Tabla 2.20.).

Modelo	Configuración del modelo						Métricas		
	Número de Capa Oculta(s)	Número de unidades ocultas	Número de ventanas	Tamaño de lote (Batch Size)	Número de épocas	Optimizador	MSE	MAE	MAPE (%)
BiLSTM	1	(2)	-	2	34	Adam	0.130	0.291	5.565
	2	(5,5)	-	2	80	Adam	0.135	0.326	6.168
GRU	1	(6)	-	10	70	Adam	0.074	0.231	4.392
	2	(5,5)	-	2	32	Adam	0.072	0.220	4.198
GA-LSTM	1	(12)	3	10	5	Adam	0.052	0.200	3.797

Tabla 2.20. La medida del desempeño de los modelos para predecir la tasa de desempleo

Además, un análisis estadístico utilizando una prueba t pareada mostró que el desempeño de GA-LSTM es comparable con el GRU de 2 capas, pero en general, el GA-LSTM predice de manera más cercana a los valores reales de la tasa de desempleo en Ecuador.

La prueba t pareada es un método estadístico empleado para evaluar si el promedio de las diferencias entre dos modelos de predicción comparados es significativamente distinto de cero. El propósito de la prueba es evaluar si los modelos predictivos emparejados presentan un rendimiento similar o distinto. La significancia estadística de la prueba se determina observando el valor p. La hipótesis se validaría con valores p cercanos a cero para los modelos predictivos pareados, mientras que los valores cercanos a 1 invalidarían la hipótesis. Se utilizó un nivel de significancia del 1% para validar la hipótesis propuesta utilizando una prueba t (valor $p \leq 0,01$).

Los resultados de la prueba t muestran que de manera general el desempeño de los modelos no es muy comparable, con pocas excepciones (GRU 2L vs GALSTM 1L, BiLSTM 1L vs GRU 1L y BiLSTM 1L

vs BiLSTM 2L) (Tabla 2.21.). En este caso, los resultados de la prueba t validan la hipótesis para la mayoría de los modelos propuestos. Por lo tanto, desde un punto de vista estadístico, esto sugiere que los modelos no tienen un rendimiento similar en la predicción de la tasa de desempleo. Se utilizó un nivel de significancia del 1% ($p \leq 0.01$), lo que significa que solo se consideran significativas las diferencias entre modelos que presenten un valor p inferior o igual a este umbral.

Modelo de regresión	BiLSTM 1L	BiLSTM 2L	GRU 1L	GRU 2L	GA-LSTM 1L
BiLSTM 1L	-	0.083	0.031	0	0
BiLSTM 2L	-	-	0	0	0
GRU 1L	-	-	-	0.002	0
GRU 2L	-	-	-	-	0.179
GA-LSTM 1L	-	-	-	-	-

Tabla 2.21. Resultados prueba t

En las comparaciones realizadas, la mayoría de los valores p no superan este umbral, lo que indica que hay evidencia estadística suficiente para concluir que existen diferencias significativas en el rendimiento de los modelos.

Por lo tanto, bajo el nivel de significancia del 1%, los resultados sugieren que el rendimiento de los modelos no es estadísticamente similar en la mayoría de los casos, lo que indica diferencias significativas en su precisión. Esto implica que los modelos tienen un desempeño diferente en la predicción de la tasa de desempleo, lo cual valida la robustez de algunos modelos en comparación con otros bajo las condiciones de este estudio. Sin embargo, existen unas pocas excepciones donde las diferencias no son significativas, lo que indica que estos modelos específicos tienen un rendimiento comparable, ya que no presentan diferencias estadísticamente significativas en sus predicciones.

Asimismo, se utilizó la prueba t pareadas para examinar si había una diferencia estadística entre las tasas de desempleo reales y las tasas predichas estimadas por los enfoques BiLSTM, GRU y GA-LSTM. Para interpretar la correlación entre los resultados se considera los criterios de baja si el coeficiente de correlación (r) está entre 0.00-0.30, moderada si el rango es de 0.30-0.70 y alta si está entre 0.70-1.00 [124].

De acuerdo con los resultados del análisis de la Tabla 2.22., existe diferencia estadísticamente significativa entre las puntuaciones reales obtenidas de la escala y las puntuaciones obtenidas con el enfoque BiLSTM 1L [$t(21)=-5.03$; $p>0.01$]. Este resultado muestra que hay diferencia entre las

puntuaciones de la tasa de desempleo estimadas por BiLSTM 1L y las puntuaciones reales. Por lo tanto, las puntuaciones reales y las puntuaciones artificiales de BiLSTM 1L no son cercanas entre sí, y el modelo BiLSTM 1L no predice resultados cercanos a las puntuaciones reales de tasa de desempleo.

Score de tasa de desempleo	N	Mean	SD	df	t	p
Real scores	22	5.39	0.32	21	-5.03	0
BiLSTM 1L scores	22	5.66	0.23	-	-	-

Tabla 2.22. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de BiLSTM 1L

De acuerdo con los resultados del análisis de la Tabla 2.23., existe diferencia estadísticamente significativa entre las puntuaciones reales obtenidas de la escala y las puntuaciones obtenidas con el enfoque BiLSTM 2L [$t(21)=-8.80$; $p>0.01$]. Este resultado muestra que hay diferencia entre las puntuaciones de la tasa de desempleo estimadas por BiLSTM 2L y las puntuaciones reales. Por lo tanto, las puntuaciones reales y las puntuaciones artificiales de BiLSTM 2L no son cercanas entre sí, y el modelo BiLSTM 2L no predice resultados cercanos a las puntuaciones reales de tasa de desempleo.

Score de tasa de desempleo	N	Mean	SD	df	t	p
Real scores	22	5.39	0.32	21	-8.80	0
BiLSTM 2L scores	22	5.72	0.26	-	-	-

Tabla 2.23. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de BiLSTM 2L

De acuerdo con los resultados del análisis de la Tabla 2.24., existe diferencia estadísticamente significativa entre las puntuaciones reales obtenidas de la escala y las puntuaciones obtenidas con el enfoque GRU 1L [$t(21)=-5.63$; $p>0.01$]. Este resultado muestra que hay diferencia entre las puntuaciones de la tasa de desempleo estimadas por GRU 1L y las puntuaciones reales. Por lo tanto, las puntuaciones reales y las puntuaciones artificiales de GRU 1L no son cercanas entre sí, y el modelo GRU 1L no predice resultados cercanos a las puntuaciones reales de tasa de desempleo.

Score de tasa de desempleo	N	Mean	SD	df	t	p
Real scores	22	5.39	0.32	21	-5.63	0
GRU 1L scores	22	5.61	0.25	-	-	-

Tabla 2.24. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de GRU 1L

De acuerdo con los resultados del análisis de la Tabla 2.25., existe diferencia estadísticamente significativa entre las puntuaciones reales obtenidas de la escala y las puntuaciones obtenidas con el enfoque GRU 2L [$t(21)=-3.23$; $p>0.01$]. Este resultado muestra que hay diferencia entre las puntuaciones de la tasa de desempleo estimadas por GRU 2L y las puntuaciones reales. Por lo tanto, las puntuaciones reales y las puntuaciones artificiales de GRU 2L no son cercanas entre sí, y el modelo GRU 2L no predice resultados cercanos a las puntuaciones reales de tasa de desempleo.

Score de tasa de desempleo	N	Mean	SD	df	t	p
Real scores	22	5.39	0.32	21	-3.23	0.004
GRU 2L scores	22	5.55	0.21	-	-	-

Tabla 2.25. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de GRU 2L

De acuerdo con los resultados del análisis de la Tabla 2.26., no existe diferencia estadísticamente significativa entre las puntuaciones reales obtenidas de la escala y las puntuaciones obtenidas con el enfoque GA-LSTM 1L [$t(18)=-2.81$; $p>0.01$]. Este resultado muestra que no hay diferencia entre las puntuaciones de la tasa de desempleo estimadas por GA-LSTM 1L y las puntuaciones reales. Por lo tanto, las puntuaciones reales y las puntuaciones artificiales de GA-LSTM 1L son cercanas entre sí, y el modelo GA-LSTM 1L predice resultados cercanos a las puntuaciones reales de tasa de desempleo.

Score de tasa de desempleo	N	Mean	SD	df	t	p
Real scores	19	5.38	0.34	18	-2,81	0.011
GA-LSTM 1L scores	19	5.50	0.28	-	-	-

Tabla 2.26. Resultados de la prueba t pareadas entre las tasas de desempleo reales y puntuaciones de GA-LSTM 1L

La Tabla 2.27. muestra los resultados de correlaciones pareadas entre las tasas de desempleo reales y puntuaciones de los modelos predictivos BiLSTM, GRU y GA-LSTM.

	N	Correlación	Sig.
Real & BiLSTM 1L scores	22	0.650	0.001
Real & BiLSTM 2L scores	22	0.846	0
Real & GRU 1L scores	22	0.844	0
Real & GRU 2L scores	22	0.726	0
Real & GA-LSTM 1L scores	19	0.821	0

Tabla 2.27. Resultados de correlaciones pareadas entre las tasas de desempleo reales y puntuaciones de los modelos de predicción

4.4. Discusión

En la predicción de la tasa de desempleo en Ecuador el modelo híbrido GA-LSTM mostró un rendimiento superior en todas las métricas en comparación con los modelos individuales referenciales BiLSTM y GRU. Se optimizaron los hiperparámetros del modelo LSTM de forma automática aplicando GA, lo cual es un desafío significativo en el aprendizaje automático debido que es complejo y no práctico probar diversas combinaciones de hiperparámetros de una red neuronal recurrente. La elección correcta de hiperparámetros en redes neuronales recurrentes del tipo LSTM, BiLSTM y GRU afecta directamente la capacidad del modelo para aprender y generalizar.

Aunque el modelo GA-LSTM logra una precisión superior en la predicción gracias a su capacidad para explorar el espacio de búsqueda y ajustar los parámetros óptimos, esta mejora de precisión viene acompañada de un aumento en la complejidad computacional y en los requisitos de recursos de entrenamiento.

El modelo híbrido GA-LSTM puede predecir con precisión los movimientos de la tasa de desempleo al identificar patrones a corto y largo plazo [125] y dependencias temporales en datos históricos secuenciales macroeconómicos clave, ofreciendo información muy útil para tomar decisiones económicas en el mercado laboral y la planificación económica [126], [127]. De la misma manera, BiLSTM y GRU tienen la capacidad de capturar dependencias a corto y largo plazo de datos secuenciales, pero lo hacen de diferente manera BiLSTM puede capturar completamente la información de datos pasados y futuros simultáneamente [128] mientras que GRU y GA-LSTM procesan la información en una dirección, hacia adelante capturando la información de datos pasados. GRU tiene menos complejidad computacional y tiempos de entrenamiento más rápidos.

Según las métricas MSE, MAE y MAPE todos los modelos de predicción demostraron un alto nivel de precisión al capturar los diversos cambios dentro del conjunto de datos, la prueba t-pareada permitió

tomar una decisión más informada respecto a las diferencias menores entre los valores reales y los predichos por el modelo *GA-LSTM* respecto a los otros modelos referenciales. Los resultados mostraron que el desempeño de los modelos *GA-LSTM (una capa)* vs. *GRU (dos capas)* y *BiLSTM (una capa)* vs. *BiLSTM (dos capas)* es muy comparable; así como, *BiLSTM (una capa)* vs. *GRU (una capa)*. Asimismo, esta prueba permitió probar si la precisión predictiva de los modelos de predicción difiere significativamente de los valores fundamentales de la tasa de desempleo, en ese sentido la prueba mostró que el modelo híbrido *GA-LSTM (una capa)* predice resultados cercanos a las puntuaciones reales de la tasa de desempleo.

Existen limitaciones importantes en la investigación, como el enfoque exclusivo en datos de Ecuador, lo cual podría restringir la generalización de los resultados a otros contextos con condiciones económicas y sociales distintas. Además, el conjunto de datos limitado en tamaño podría no haber evaluado del todo la robustez del modelo, especialmente en la presencia de factores adicionales que influyen en el desempleo. Los datos seleccionados como variables independientes (salario mínimo, PIB y FBCF) en este estudio pueden no capturar completamente la complejidad del mercado laboral, lo cual limita la capacidad del modelo para generalizar a otros contextos donde otras variables podrían ser relevantes.

CONCLUSIONES Y TRABAJOS FUTUROS

En el capítulo final se sintetizan las conclusiones principales de la investigación, destacando las contribuciones realizadas al campo de la predicción económica mediante técnicas avanzadas de redes neuronales LSTM y algoritmos genéticos. Se reflexiona sobre los hallazgos obtenidos, su impacto en la mejora de las proyecciones económicas y las posibles aplicaciones en otros indicadores económicos. Asimismo, se identifican las limitaciones del estudio y se proponen líneas de investigación futura para optimizar el modelo desarrollado y explorar su aplicabilidad en diferentes contextos económicos y sociales.

5.1. Conclusiones

Esta tesis doctoral contribuyó al desarrollo de un modelo predictivo híbrido para la predicción de la tasa de desempleo en Ecuador mediante la combinación de redes neuronales LSTM y GA (GA-LSTM). A partir de un análisis exhaustivo de diferentes métodos de inteligencia artificial aplicados a la predicción de indicadores económicos, se concluyó que el modelo GA-LSTM, optimizado para captar relaciones complejas y patrones temporales, proporciona una precisión superior en comparación con otros modelos, como BiLSTM y GRU. Esta precisión sugiere que el enfoque propuesto es robusto y adecuado para abordar la complejidad de los datos económicos en entornos dinámicos y no lineales como el mercado laboral ecuatoriano. La investigación ha logrado demostrar que la optimización de hiperparámetros mediante algoritmos genéticos es efectiva para mejorar la capacidad predictiva de las redes neuronales, lo cual puede facilitar la toma de decisiones en políticas públicas y planificación económica.

- La revisión exhaustiva de la literatura permitió identificar y clasificar los diversos métodos de IA utilizados en la predicción de indicadores económicos, respecto a la tasa de desempleo, el PIB, la inflación, el IPC y la tasa de cambio. Los modelos más empleados incluyen las ANNs, Vectores de Soporte (SVM/SVR), y los modelos híbridos como ARIMA-ANN, ARIMA-SVM, LSTM-PSO y LSTM-GRU, ELM y otras técnicas de aprendizaje automático.

- El modelo híbrido GA-LSTM demostró ser una solución innovadora y efectiva para mejorar la precisión en la predicción de la tasa de desempleo en Ecuador ya que la integración de técnicas evolutivas para la optimización de hiperparámetros permite al modelo capturar patrones complejos y no lineales. Ese modelo superó el desempeño de modelos tradicionales de redes neuronales recurrentes.
- La aplicación de GA para la optimización de hiperparámetros es crucial para maximizar la precisión del modelo predictivo, específicamente se ajustaron el tamaño de la ventana de tiempo y el número de unidades LSTM lo que permitió que el modelo GA-LSTM alcanzara resultados superiores en términos de métricas de error como MSE, MAE y MAPE; de esta manera se redujo significativamente la desviación en las predicciones.
- Las pruebas experimentales confirmaron que el modelo GA-LSTM supera significativamente en precisión a los modelos BiLSTM y GRU en la predicción de la tasa de desempleo. Este resultado muestra la efectividad del modelo híbrido que combina las fortalezas de las técnicas de redes neuronales LSTM con las capacidades optimizadoras de los algoritmos genéticos.

5.2. Trabajos futuros

A partir de los resultados obtenidos, se identifican varias líneas de investigación para futuros trabajos:

- Una línea futura de investigación sería extender el modelo híbrido GA-LSTM para la predicción de otros indicadores económicos, como el Producto Interno Bruto (PIB) o el Índice de Precios al Consumidor (IPC). Esto permitiría evaluar la capacidad del modelo para manejar datos con diferentes patrones y complejidades. Estudios previos han demostrado la efectividad de enfoques híbridos en la predicción del PIB utilizando técnicas similares (WA-LSTM, LSTM-PSO) [129], [130], lo que respalda la viabilidad de esta propuesta.
- Otra área de interés sería la integración de variables externas, como indicadores globales de comercio o precios del petróleo en el modelo actual, adicional a los indicadores nacionales. Esto podría mejorar la precisión de las predicciones al capturar el impacto de factores externos en la tasa de desempleo. La literatura sugiere que los datos externos pueden ser un complemento crucial para modelos predictivos en economías dependientes de factores externos [131].

- Finalmente, se recomienda realizar un análisis comparativo del modelo GA-LSTM con otros enfoques avanzados de inteligencia artificial, híbridos e individuales (puros) como ARIMA-ARNN, BMA-PAR, ARMAX-GARCHX, LSTM-GRU, NNAR y FTS. Estudios recientes han destacado la efectividad de estas técnicas en problemas de predicción de la tasa de desempleo [132], [132], [133], [134], [135], [136], lo que abre la posibilidad de identificar enfoques aún más precisos o adaptables.

5.3. Difusión de resultados

Título	Artificial intelligence and its impact on the prediction of economic indicators
Autores	Kevin Mero, Jaime Meza, Sebastián Ventura
Tipo de publicación	Artículo en conferencia
Título de las actas	Proceedings of the 6th International Conference on Engineering & MIS 2020
Catálogo de biblioteca	Association for Computing Machinery (ACM)
Año	2020
Mes	Septiembre
ISBN	978-145037736-2
DOI	https://doi.org/10.1145/3410352.3410827
Categoría	Ingeniería & Sistemas de Información Gerencial
Indexaciones	Scopus, Google Académico

En la participación en la ponencia ICEMIS'20 se presentaron los resultados de la revisión bibliográfica sistemática sobre los métodos de IA empleados en la predicción de indicadores económicos. La investigación se llevó a cabo mediante un análisis exhaustivo de artículos científicos publicados entre 2015 y 2019 los cuales fueron obtenidos de bases de datos como Web of Science, Scopus y Google Scholar. Durante la ponencia, se discutieron los hallazgos sobre los métodos más utilizados en la predicción de indicadores económicos, entre los que destacan la programación genética, las redes neuronales artificiales, las máquinas de aprendizaje extremo y otras técnicas de aprendizaje automático. Asimismo, se discutieron las aplicaciones prácticas y el impacto de estos modelos en la toma de decisiones económicas.

Los resultados fueron obtenidos siguiendo las directrices de la metodología Systematic reviews and Meta-Analyses (PRISMA) la cual permitió documentar como se realizó la revisión sistemática. Estos resultados proporcionan una base de referencia para investigadores y profesionales interesados en desarrollar modelos predictivos de indicadores económicos. Los hallazgos destacaron la efectividad

y precisión de los modelos de IA en la gestión y análisis de datos económicos caracterizados por su naturaleza no lineal y compleja.

Título	Unemployment Rate Prediction Using a Hybrid Model of Recurrent Neural Networks and Genetic Algorithms
Autores	Kevin Mero, Jaime Meza, Janeth Pacheco-Delgado, Sebastián Ventura
Tipo de publicación	Artículo de investigación
Nombre de la publicación	Applied Sciences
Editorial	MDPI
Año	2024
Mes	Abril
DOI	https://doi.org/10.3390/app14083174
Categoría	Ingeniería
SJR - SCImago Journal Rank (2023)	0.51 (Q2)
JCR - Journal Citation Reports (2023)	2.5 (Q1)
Indexaciones	Web of Science, Scopus

Este estudio propone un enfoque híbrido para predecir la tasa de desempleo en Ecuador mediante el uso de una red neuronal LSTM combinada con GA denominada GA-LSTM, este modelo híbrido busca abordar las complejidades inherentes a la predicción de datos secuenciales y no lineales de la tasa de desempleo optimizando hiperparámetros clave de la red neuronal, específicamente el tamaño de la ventana y unidades ocultas. Como variables económicas relevantes se seleccionaron el salario mínimo, el PIB y la FBCF y como variable objetiva la tasa de desempleo; dichas variables independientes tienen una correlación significativa con el desempleo.

La propuesta evalúa el desempeño del modelo GA-LSTM en comparación con las redes neuronales recurrentes tradicionales BiLSTM y GRU. Los resultados muestran que el modelo híbrido supera en precisión a los modelos individuales, sugiriendo que la integración de la capacidad de optimización de GA con la capacidad predictiva de LSTM proporciona una solución efectiva para la predicción de la tasa de desempleo en el contexto ecuatoriano.

Bibliografía

- [1] T. Balabanov, I. Zankinski, y N. Dobrinkova, «Time Series Prediction by Artificial Neural Networks and Differential Evolution in Distributed Environment», en *Large-Scale Scientific Computing*, I. Lirkov, S. Margenov, y J. Waśniewski, Eds., Berlin, Heidelberg: Springer, 2012, pp. 198-205. doi: 10.1007/978-3-642-29843-1_22.
- [2] R. S. Raj y M. Kusuma, «Performance Evaluation for Building a Predictive Model on Diabetic Health Record using PySpark», *IJCRT - Int. J. Creat. Res. Thoughts IJCRT*, vol. 10, n.º 9, pp. a481-a489, sep. 2022.
- [3] A. Thakurdesai, «Stock Price Prediction Using Machine Learning», *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 12, n.º 10, pp. 1432-1438, oct. 2024, doi: 10.22214/ijraset.2024.64895.
- [4] «Definition of predict». Accedido: 3 de febrero de 2024. [En línea]. Disponible en: <https://www.merriam-webster.com/dictionary/predict>
- [5] H. Publishers, «The American Heritage Dictionary entry: predict». Accedido: 3 de febrero de 2024. [En línea]. Disponible en: <https://www.ahdictionary.com/word/search.html?q=predict>
- [6] «Definition of forecasting». Accedido: 3 de febrero de 2024. [En línea]. Disponible en: <https://www.merriam-webster.com/dictionary/forecasting>
- [7] H. Publishers, «The American Heritage Dictionary entry: forecasting». Accedido: 3 de febrero de 2024. [En línea]. Disponible en: <https://www.ahdictionary.com/word/search.html?q=forecasting>
- [8] R. G. Brown, *Smoothing, Forecasting and Prediction of Discrete Time Series*. Dover Corporation, 2004. [En línea]. Disponible en: <https://babel.hathitrust.org/cgi/pt?id=mdp.39015004514728&seq=1>
- [9] Y. Chen *et al.*, «Development of a Time Series E-Commerce Sales Prediction Method for Short-Shelf-Life Products Using GRU-LightGBM», *Appl. Sci.*, vol. 14, n.º 2, Art. n.º 2, ene. 2024, doi: 10.3390/app14020866.
- [10] R. M. van Steenberg y M. R. K. Mes, «Forecasting demand profiles of new products», *Decis. Support Syst.*, vol. 139, p. 113401, dic. 2020, doi: 10.1016/j.dss.2020.113401.
- [11] S. Shin, M. Lee, y S. Song, «A Prediction Model for Agricultural Products Price with LSTM Network», *J. Korea Contents Assoc.*, vol. 18, n.º 11, pp. 416-429, 2018, doi: 10.5392/JKCA.2018.18.11.416.
- [12] Q. Zhao, Z. Zhao, L. Yang, L. Hong, y W. Han, «Research on Customer Retention Prediction Model of VOD Platform Based on Machine Learning», *Int. J. Adv. Comput. Sci. Appl. IJACSA*, vol. 14, n.º 4, Art. n.º 4, 38/29 2023, doi: 10.14569/IJACSA.2023.0140427.
- [13] C. Xin, F. Guo, y A. Wang, «Exploring the impacts of China's water resource tax policies: A Trade-Off Between Economic Development and Ecological Protection», *Front. Environ. Sci.*, vol. 10, nov. 2022, doi: 10.3389/fenvs.2022.982085.
- [14] D. S. Cristea *et al.*, «Modelling the Common Agricultural Policy Impact over the EU Agricultural and Rural Environment through a Machine Learning Predictive Framework», *Agronomy*, vol. 11, n.º 11, Art. n.º 11, nov. 2021, doi: 10.3390/agronomy11112105.
- [15] D. Jia y W. Yin, «Continuous blood pressure prediction based on hierarchical adaptive algorithm», en *PROCEEDINGS OF 2020 IEEE 4TH INFORMATION TECHNOLOGY, NETWORKING, ELECTRONIC AND AUTOMATION CONTROL CONFERENCE (ITNEC 2020)*, B. Xu y K. Mou, Eds., New York: IEEE, 2020, pp. 934-938. Accedido: 20 de abril de 2024. [En línea]. Disponible en: <https://www.webofscience.com/wos/alldb/full-record/WOS:000588278500179>
- [16] W. Zhu, L. Xie, J. Han, y X. Guo, «The Application of Deep Learning in Cancer Prognosis Prediction», *CANCERS*, vol. 12, n.º 3, p. 603, mar. 2020, doi: 10.3390/cancers12030603.

- [17] J. Stevenson-Hoare *et al.*, «Plasma biomarkers and genetics in the diagnosis and prediction of Alzheimer's disease», *Brain*, vol. 146, n.º 2, Art. n.º 2, feb. 2023, doi: 10.1093/brain/awac128.
- [18] T. Ge, C.-Y. Chen, Y. Ni, Y.-C. A. Feng, y J. W. Smoller, «Polygenic prediction via Bayesian regression and continuous shrinkage priors», *Nat. Commun.*, vol. 10, n.º 1, Art. n.º 1, abr. 2019, doi: 10.1038/s41467-019-09718-5.
- [19] K. Betts, S. Kisely, y R. Alati, «Predicting common maternal postpartum complications: leveraging health administrative data and machine learning», *BJOG Int. J. Obstet. Gynaecol.*, vol. 126, n.º 6, pp. 702-709, 2019, doi: 10.1111/1471-0528.15607.
- [20] B. N. Lakshmi, T. S. Indumathi, y N. Ravi, «An Hybrid Approach for Prediction Based Health Monitoring in Pregnant Women», *Procedia Technol.*, vol. 24, pp. 1635-1642, ene. 2016, doi: 10.1016/j.protcy.2016.05.171.
- [21] K. Wong, G. A. Tessema, K. Chai, y G. Pereira, «Development of prognostic model for preterm birth using machine learning in a population-based cohort of Western Australia births between 1980 and 2015», *Scientific Reports*, vol. 12, n.º 1, p. 19153, 2022.
- [22] Q. Li, G. Yan, y C. Yu, «A Novel Multi-Factor Three-Step Feature Selection and Deep Learning Framework for Regional GDP Prediction: Evidence from China», *Sustainability*, vol. 14, n.º 8, Art. n.º 8, ene. 2022, doi: 10.3390/su14084408.
- [23] D. Marković, D. Petković, V. Nikolić, M. Milovančević, y B. Petković, «Soft computing prediction of economic growth based in science and technology factors», *Phys. Stat. Mech. Its Appl.*, vol. 465, pp. 217-220, ene. 2017, doi: 10.1016/j.physa.2016.08.034.
- [24] G. S. Araujo y W. P. Gaglianone, «Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models», *Lat. Am. J. Cent. Bank.*, vol. 4, n.º 2, p. 100087, jun. 2023, doi: 10.1016/j.latcb.2023.100087.
- [25] A. Ang, G. Bekaert, y M. Wei, «Do macro variables, asset markets, or surveys forecast inflation better?», *J. Monet. Econ.*, vol. 54, n.º 4, pp. 1163-1212, may 2007, doi: 10.1016/j.jmoneco.2006.04.006.
- [26] T. Han, H. Wang, X. Hao, y S. Li, «Seasonal Prediction of Midsummer Extreme Precipitation Days over Northeast China», sep. 2019, doi: 10.1175/JAMC-D-18-0253.1.
- [27] Z. Yan, J. Li, W. Zhou, Z. Lin, Y. Zang, y S. Li, «Evaluation of Seasonal Prediction of Extreme Wind Resource Potential over China Based on a Dynamic Prediction System SIDRI-ESS V1.0», *Atmosphere*, vol. 15, n.º 9, Art. n.º 9, sep. 2024, doi: 10.3390/atmos15091024.
- [28] L. Batté, I. Välisuo, M. Chevallier, J. C. Acosta Navarro, P. Ortega, y D. Smith, «Summer Predictions of Arctic Sea Ice Edge in Multi-Model Seasonal Re-Forecasts», *Clim. Dyn.*, vol. 54, n.º 11, pp. 5013-5029, jun. 2020, doi: 10.1007/s00382-020-05273-8.
- [29] E. Pasero, W. Moniaci, y T. Meindl, «Intelligent systems for meteorological events forecast», en *Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005.*, jul. 2005, pp. 2686-2688 vol. 5. doi: 10.1109/IJCNN.2005.1556348.
- [30] J. Liu, S. Zhang, y H. Fan, «A two-stage hybrid credit risk prediction model based on XGBoost and graph-based deep neural network», *Expert Syst. Appl.*, vol. 195, p. 116624, jun. 2022, doi: 10.1016/j.eswa.2022.116624.
- [31] Y. Hu y J. Su, «Research on Credit Risk Evaluation of Commercial Banks Based on Artificial Neural Network Model», *Procedia Comput. Sci.*, vol. 199, pp. 1168-1176, ene. 2022, doi: 10.1016/j.procs.2022.01.148.
- [32] N. K. Gyamfi y J.-D. Abdulai, «Bank Fraud Detection Using Support Vector Machine», en *2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, nov. 2018, pp. 37-41. doi: 10.1109/IEMCON.2018.8614994.
- [33] J. B. Awotunde, S. Misra, F. Ayeni, R. Maskeliunas, y R. Damasevicius, «Artificial Intelligence Based System for Bank Loan Fraud Prediction», en *Hybrid Intelligent Systems*, A. Abraham, P.

- Siarry, V. Piuri, N. Gandhi, G. Casalino, O. Castillo, y P. Hung, Eds., Cham: Springer International Publishing, 2022, pp. 463-472. doi: 10.1007/978-3-030-96305-7_43.
- [34] P. Wasan, «Predicting customer experience and discretionary behaviors of bank customers in India», *Int. J. Bank Mark.*, vol. 36, n.º 4, pp. 701-725, ene. 2018, doi: 10.1108/IJBM-06-2017-0121.
- [35] N. Zeinalizadeh, A. A. Shojaie, y M. Shariatmadari, «Modeling and analysis of bank customer satisfaction using neural networks approach», *Int. J. Bank Mark.*, vol. 33, n.º 6, pp. 717-732, ene. 2015, doi: 10.1108/IJBM-06-2014-0070.
- [36] L. Mirghaderi, M. Sziron, y E. Hildt, «Investigating user perceptions of commercial virtual assistants: A qualitative study», *Front. Psychol.*, vol. 13, sep. 2022, doi: 10.3389/fpsyg.2022.944714.
- [37] I. Adjabi, A. Ouahabi, A. Benzaoui, y A. Taleb-Ahmed, «Past, Present, and Future of Face Recognition: A Review», *Electronics*, vol. 9, n.º 8, Art. n.º 8, ago. 2020, doi: 10.3390/electronics9081188.
- [38] Y. Guo, Y. Xia, J. Wang, H. Yu, y R.-C. Chen, «Real-Time Facial Affective Computing on Mobile Devices», *Sensors*, vol. 20, n.º 3, Art. n.º 3, ene. 2020, doi: 10.3390/s20030870.
- [39] M. Constantino, D. R. F. Mendes, y T. B. S. Moreira, «Análise e previsão da taxa de inflação no Brasil: uma abordagem via modelo SARIMA», *Rev. Científica Hermes*, vol. 24, pp. 244-257, may 2019, doi: 10.21710/rch.v24i0.446.
- [40] S. L. James, P. Gubbins, C. J. Murray, y E. Gakidou, «Developing a comprehensive time series of GDP per capita for 210 countries from 1950 to 2015», *Popul. Health Metr.*, vol. 10, n.º 1, p. 12, jul. 2012, doi: 10.1186/1478-7954-10-12.
- [41] S. Gupta y S. Kashyap, «Forecasting inflation in G-7 countries: an application of artificial neural network», *Foresight*, vol. 17, n.º 1, pp. 63-73, ene. 2015, doi: 10.1108/FS-09-2013-0045.
- [42] H. Guo, «Stock Market Dispersion and Unemployment», *Natl. Econ. Trends*, n.º Feb, 2007, Accedido: 10 de noviembre de 2024. [En línea]. Disponible en: <https://ideas.repec.org//a/fip/fedlne/y2007ifeb.html>
- [43] B. Sherwood, A. X.-H. Zhou, S. Weintraub, y L. Wang, «Using Quantile Regression to Create Baseline Norms for Neuropsychological Tests», *Alzheimers Dement. Diagn. Assess. Dis. Monit.*, vol. 2, pp. 12-18, ene. 2016, doi: 10.1016/j.dadm.2015.11.005.
- [44] P. K. Pandey, H. Tripura, y V. Pandey, «Improving Prediction Accuracy of Rainfall Time Series By Hybrid SARIMA–GARCH Modeling», *Nat. Resour. Res.*, vol. 28, n.º 3, pp. 1125-1138, jul. 2019, doi: 10.1007/s11053-018-9442-z.
- [45] R. Arisanti y M. D. Puspita, «Non-linear autoregressive neural network with exogenous variable in forecasting USD/IDR exchange rate», *Commun Math Biol Neurosci*, vol. 2022, n.º 0, p. Article ID 5, ene. 2022, doi: 10.28919/cmbn/6931.
- [46] J. D. Kelleher, B. Mac Namee, y A. D' Arcy, *Fundamentals of Machine Learning for Predictive Data Analytics*, Second. The MIT Pres, 2020. Accedido: 20 de octubre de 2024. [En línea]. Disponible en: <https://mitpress.mit.edu/9780262044691/fundamentals-of-machine-learning-for-predictive-data-analytics/>
- [47] D. H. Wolpert, «The Lack of A Priori Distinctions Between Learning Algorithms», *Neural Comput.*, vol. 8, n.º 7, pp. 1341-1390, oct. 1996, doi: 10.1162/neco.1996.8.7.1341.
- [48] «Amazon Machine Learning - Developer Guide». Amazon Web Services, Inc. and/or its affiliates, 2024. Accedido: 21 de octubre de 2024. [En línea]. Disponible en: <https://docs.aws.amazon.com/pdfs/machine-learning/latest/dg/machinelearning-dg.pdf>
- [49] K. Mero-Ramírez, J. Meza-Hormaza, y S. Ventura-Soto, «Artificial intelligence and its impact on the prediction of economic indicators», en *Proceedings of the 6th International*

- Conference on Engineering & MIS 2020*, en ICEMIS'20. New York, NY, USA: Association for Computing Machinery, sep. 2020, pp. 1-8. doi: 10.1145/3410352.3410827.
- [50] M. Stevanović, S. Vujičić, y A. M. Gajić, «Gross domestic product estimation based on electricity utilization by artificial neural network», *Phys. Stat. Mech. Its Appl.*, vol. 489, pp. 28-31, ene. 2018, doi: 10.1016/j.physa.2017.07.023.
- [51] V. Marjanović, M. Milovančević, y I. Mladenović, «Prediction of GDP growth rate based on carbon dioxide (CO2) emissions», *J. CO2 Util.*, vol. 16, pp. 212-217, dic. 2016, doi: 10.1016/j.jcou.2016.07.009.
- [52] A. A. Davidescu, S.-A. Apostu, y A. Paul, «Comparative Analysis of Different Univariate Forecasting Methods in Modelling and Predicting the Romanian Unemployment Rate for the Period 2021-2022», *Entropy*, vol. 23, n.º 3, p. 325, mar. 2021, doi: 10.3390/e23030325.
- [53] A. Vosseler y E. Weber, «Forecasting seasonal time series data: a Bayesian model averaging approach», *Comput. Stat.*, vol. 33, n.º 4, pp. 1733-1765, dic. 2018, doi: 10.1007/s00180-018-0801-3.
- [54] C. Katris, «Prediction of Unemployment Rates with Time Series and Machine Learning Techniques», *Comput. Econ.*, vol. 55, n.º 2, pp. 673-706, feb. 2020, doi: 10.1007/s10614-019-09908-9.
- [55] L. Shi, Y. A. Khan, y M.-W. Tian, «COVID-19 pandemic and unemployment rate prediction for developing countries of Asia: A hybrid approach», *PLOS ONE*, vol. 17, n.º 12, p. e0275422, dic. 2022, doi: 10.1371/journal.pone.0275422.
- [56] J. Eklund y J.-M. Kim, «Forecasting Consumer Price Index with Federal Open Market Committee Sentiment Index», *J. Forecast.*, vol. n/a, n.º n/a, doi: 10.1002/for.3109.
- [57] X. Zeng, L. Shu, G. Huang, y J. Jiang, «Triangular Fuzzy Series Forecasting Based on Grey Model and Neural Network», *Appl. Math. Model.*, vol. 40, n.º 3, pp. 1717-1727, feb. 2016, doi: 10.1016/j.apm.2015.08.009.
- [58] J. Wang, L. Sun, H. Zhao, y Y. Wang, «ARIMA-BP integrated intelligent algorithm for China's consumer price index forecasting and its applications», *J. Intell. Fuzzy Syst.*, vol. 31, n.º 4, pp. 2187-2193, ene. 2016, doi: 10.3233/JIFS-169058.
- [59] C. Lu, Z. Teng, Y. Gao, R. Wu, Md. A. Hossain, y Y. Fang, «Analysis of Early Warning of RMB Exchange Rate Fluctuation and Value at Risk Measurement Based on Deep Learning», *Comput. Econ.*, vol. 59, n.º 4, pp. 1501-1524, abr. 2022, doi: 10.1007/s10614-021-10172-z.
- [60] T. Luo, L. Zhang, H. Sun, y J. Bai, «Enhancing exchange rate volatility prediction accuracy: Assessing the influence of different indices on the USD/CNY exchange rate», *Finance Res. Lett.*, vol. 58, p. 104483, dic. 2023, doi: 10.1016/j.frl.2023.104483.
- [61] J. Wang, X. Wang, J. Li, y H. Wang, «A Prediction Model of CNN-TLSTM for USD/CNY Exchange Rate Prediction», *IEEE Access*, vol. 9, pp. 73346-73354, 2021, doi: 10.1109/ACCESS.2021.3080459.
- [62] M. Wang, K. Chen, Q. Luo, y C. Cheng, «Multi-Step Inflation Prediction with Functional Coefficient Autoregressive Model», *Sustainability*, vol. 10, n.º 6, Art. n.º 6, jun. 2018, doi: 10.3390/su10061691.
- [63] C. Yang y S. Guo, «Inflation Prediction Method Based on Deep Learning», *Comput. Intell. Neurosci.*, vol. 2021, n.º 1, p. 1071145, 2021, doi: 10.1155/2021/1071145.
- [64] M. Y. Shams, Z. Tarek, E.-S. M. El-kenawy, M. M. Eid, y A. M. Elshewey, «Predicting Gross Domestic Product (GDP) using a PC-LSTM-RNN model in urban profiling areas», *Comput. Urban Sci.*, vol. 4, n.º 1, p. 3, ene. 2024, doi: 10.1007/s43762-024-00116-2.
- [65] W. Xie, H. Wu, B. Liu, S. Mu, y N. Nadia, «Study on Exchange Rate Forecasting with Stacked Optimization Based on a Learning Algorithm», *Mathematics*, vol. 12, n.º 4, Art. n.º 4, ene. 2024, doi: 10.3390/math12040614.

- [66] S. Liu, Q. Huang, M. Li, y Y. Wei, «A New LASSO-BiLSTM-Based Ensemble Learning Approach for Exchange Rate Forecasting», *Eng. Appl. Artif. Intell.*, vol. 127, p. 107305, ene. 2024, doi: 10.1016/j.engappai.2023.107305.
- [67] J. Wang, M. He, W. Xu, y F. Jing, «A Deep Learning-Based Nonlinear Ensemble Approach with Biphasic Feature Selection for Multivariate Exchange Rate Forecasting», *Multimed. Tools Appl.*, vol. 82, n.º 15, pp. 22961-22979, feb. 2023, doi: 10.1007/s11042-023-14497-9.
- [68] R. Kausar, F. Iqbal, A. Raziq, y N. Sheikh, «A Hybrid Approach for Accurate Forecasting of Exchange Rate Prices using VMDCEEMDAN-GRU-ATCN Model», *SAINS Malays.*, vol. 52, n.º 11, pp. 3293-3306, nov. 2023, doi: 10.17576/jsm-2023-5211-20.
- [69] R. Arisanti, Y. Nurhasanah, y S. Winarni, «A NARX-NN Optimization Algorithm for Forecasting Inflation During a Potential Recession Period Using Longitudinal Data», *Commun Math Biol Neurosci*, vol. 2023, n.º 0, p. Article ID 43, may 2023, doi: 10.28919/cmbn/7932.
- [70] S. Kumar, A. K. Shukla, P. K. Muhuri, y Q. M. D. Lohani, «CO2 emission based GDP prediction using intuitionistic fuzzy transfer learning», *Ecol. Inform.*, vol. 77, p. 102206, nov. 2023, doi: 10.1016/j.ecoinf.2023.102206.
- [71] Y. Zhang y S. Hamori, «The Predictability of the Exchange Rate When Combining Machine Learning and Fundamental Models», *J. Risk Financ. Manag.*, vol. 13, n.º 3, Art. n.º 3, mar. 2020, doi: 10.3390/jrfm13030048.
- [72] Q. Li, C. Yu, y G. Yan, «A New Multipredictor Ensemble Decision Framework Based on Deep Reinforcement Learning for Regional GDP Prediction», *IEEE Access*, vol. 10, pp. 45266-45279, 2022, doi: 10.1109/ACCESS.2022.3170905.
- [73] X. Xu, R. A. Rogers, y M. A. R. Estrada, «A Novel Prediction Model: ELM-ABC for Annual GDP in the Case of SCO Countries», *Comput. Econ.*, vol. 62, n.º 4, pp. 1545-1566, dic. 2023, doi: 10.1007/s10614-022-10311-0.
- [74] J. Ortega-Bastida, A. J. Gallego, J. R. Rico-Juan, y P. Albarrán, «A multimodal approach for regional GDP prediction using social media activity and historical information», *Appl. Soft Comput.*, vol. 111, p. 107693, nov. 2021, doi: 10.1016/j.asoc.2021.107693.
- [75] X. Wu, Z. Zhang, H. Chang, y Q. Huang, «A Data-Driven Gross Domestic Product Forecasting Model Based on Multi-Indicator Assessment», *IEEE Access*, vol. 9, pp. 99495-99503, 2021, doi: 10.1109/ACCESS.2021.3062671.
- [76] T. Chakraborty, A. K. Chakraborty, M. Biswas, S. Banerjee, y S. Bhattacharya, «Unemployment Rate Forecasting: A Hybrid Approach», *Comput. Econ.*, vol. 57, n.º 1, pp. 183-201, ene. 2021, doi: 10.1007/s10614-020-10040-2.
- [77] M. Ahmad, Y. A. Khan, C. Jiang, S. J. H. Kazmi, y S. Z. Abbas, «The impact of COVID-19 on unemployment rate: An intelligent based unemployment rate prediction in selected countries of Europe», *Int. J. Finance Econ.*, vol. n/a, n.º n/a, doi: 10.1002/ijfe.2434.
- [78] M. Yurtsever, «Unemployment rate forecasting: LSTM-GRU hybrid approach», *J. Labour Mark. Res.*, vol. 57, n.º 1, p. 18, jun. 2023, doi: 10.1186/s12651-023-00345-8.
- [79] P. K. Sarangi, A. K. Sahoo, y S. Sinha, «Modeling Consumer Price Index: A Machine Learning Approach», *Macromol. Symp.*, vol. 401, n.º 1, p. 2100349, 2022, doi: 10.1002/masy.202100349.
- [80] M. Álvarez-Díaz y R. Gupta, «Forecasting US consumer price index: does nonlinearity matter?», *Appl. Econ.*, vol. 48, n.º 46, pp. 4462-4475, oct. 2016, doi: 10.1080/00036846.2016.1158922.
- [81] B. Powell, G. Nason, D. Elliott, M. Mayhew, J. Davies, y J. Winton, «Tracking and Modelling Prices Using Web-Scraped Price Microdata: Towards Automated Daily Consumer Price Index Forecasting», *J. R. Stat. Soc. Ser. A Stat. Soc.*, vol. 181, n.º 3, pp. 737-756, jun. 2018, doi: 10.1111/rssa.12314.

- [82] P. T. Kanda, M. Balcilar, P. Bahramian, y R. Gupta, «Forecasting South African inflation using non-linear models: a weighted loss-based evaluation», *Appl. Econ.*, vol. 48, n.º 26, pp. 2412-2427, jun. 2016, doi: 10.1080/00036846.2015.1122731.
- [83] N. Mirza, S. K. A. Rizvi, B. Naqvi, y M. Umar, «Inflation prediction in emerging economies: Machine learning and FX reserves integration for enhanced forecasting», *Int. Rev. Financ. Anal.*, vol. 94, p. 103238, jul. 2024, doi: 10.1016/j.irfa.2024.103238.
- [84] A. A. Naghi, E. O'Neill, y M. Danielova Zaharieva, «The Benefits of Forecasting Inflation with Machine Learning: New Evidence», *J. Appl. Econom.*, vol. n/a, n.º n/a, doi: 10.1002/jae.3088.
- [85] J.-F. Verne, «Forecast the inflation rate in Lebanon: The use of the artificial neural networks method», *Econ. Bull.*, vol. 42, n.º 4, pp. 1798-1810, 2022.
- [86] A. P. Engelbrecht, *Computational Intelligence*. John Wiley & Sons, Ltd, 2007. doi: 10.1002/9780470512517.fmatter.
- [87] L. D. L. Daniela, R. Guillermo, y P. Darío, «Inteligencia Computacional». Accedido: 7 de enero de 2025. [En línea]. Disponible en: <https://attend.ieee.org/argencon-2022/programa/inteligencia-computacional/>
- [88] K. Bhargavi, «Classification of DNA Sequence Using Soft Computing Techniques: A Survey», *Indian J. Sci. Technol.*, vol. 9, n.º 1, pp. 1-7, ene. 2016, doi: 10.17485/ijst/2016/v9i47/89343.
- [89] A. Graves, M. Liwicki, S. Fernández, R. Bertolami, H. Bunke, y J. Schmidhuber, «A Novel Connectionist System for Unconstrained Handwriting Recognition», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 31, n.º 5, pp. 855-868, may 2009, doi: 10.1109/TPAMI.2008.137.
- [90] X. M. Zhang, Q. L. Han, X. Ge, y D. Ding, «An overview of recent developments in Lyapunov-Krasovskii functionals and stability criteria for recurrent neural networks with time-varying delays», *Neurocomputing*, vol. 313, pp. 392-401, nov. 2018, doi: 10.1016/j.neucom.2018.06.038.
- [91] J. Wang, «Speech recognition in English cultural promotion via recurrent neural network», *Pers. Ubiquitous Comput.*, vol. 24, n.º 2, pp. 237-246, abr. 2020, doi: 10.1007/s00779-019-01293-2.
- [92] S. B. Ahmed, S. Naz, M. I. Razzak, S. F. Rashid, M. Z. Afzal, y T. M. Breuel, «Evaluation of cursive and non-cursive scripts using recurrent neural networks», *Neural Comput. Appl.*, vol. 27, n.º 3, pp. 603-613, abr. 2016, doi: 10.1007/s00521-015-1881-4.
- [93] S. K. Mahata, D. Das, y S. Bandyopadhyay, «MTIL2017: Machine Translation Using Recurrent Neural Network on Statistical Machine Translation», *J. Intell. Syst.*, vol. 28, n.º 3, pp. 447-453, jul. 2019, doi: 10.1515/jisys-2018-0016.
- [94] C. Lee, «Image Caption Generation using Recurrent Neural Network», *J. KIISE*, vol. 43, n.º 08, pp. 878-882, 2016.
- [95] I. Ofodile *et al.*, «Action Recognition Using Single-Pixel Time-of-Flight Detection», *Entropy*, vol. 21, n.º 4, Art. n.º 4, abr. 2019, doi: 10.3390/e21040414.
- [96] Y. Zhang, Y. Ming, y R. Zhang, «Object Detection and Tracking based on Recurrent Neural Networks», en *2018 14th IEEE International Conference on Signal Processing (ICSP)*, ago. 2018, pp. 338-343. doi: 10.1109/ICSP.2018.8652389.
- [97] T. Ziemke, «Radar image segmentation using recurrent artificial neural networks», *Pattern Recognit. Lett.*, vol. 17, n.º 4, pp. 319-334, abr. 1996, doi: 10.1016/0167-8655(95)00128-X.
- [98] S. Hochreiter y J. Schmidhuber, «Long Short-Term Memory», *Comput. Neuronal*, vol. 9, n.º 8, pp. 1735-1780, nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [99] H. Chung y K. Shin, «Genetic Algorithm-Optimized Long Short-Term Memory Network for Stock Market Prediction», *Sustainability*, vol. 10, n.º 10, p. 3765, oct. 2018, doi: 10.3390/su10103765.

- [100] S. Siami-Namini, N. Tavakoli, y A. S. Namin, «The Performance of LSTM and BiLSTM in Forecasting Time Series», en *2019 IEEE International Conference on Big Data (Big Data)*, dic. 2019, pp. 3285-3292. doi: 10.1109/BigData47090.2019.9005997.
- [101] A. Graves, N. Jaitly, y A. Mohamed, «Hybrid speech recognition with Deep Bidirectional LSTM», en *2013 IEEE Workshop on Automatic Speech Recognition and Understanding*, dic. 2013, pp. 273-278. doi: 10.1109/ASRU.2013.6707742.
- [102] S. Sun y Z. Xie, «BiLSTM-Based Models for Metaphor Detection», en *Natural Language Processing and Chinese Computing*, X. Huang, J. Jiang, D. Zhao, Y. Feng, y Y. Hong, Eds., en *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2018, pp. 431-442. doi: 10.1007/978-3-319-73618-1_36.
- [103] L. Liu, B. Bai, X. Chen, y Q. Xia, «Semantic Segmentation of QRS Complex in Single Channel ECG with Bidirectional LSTM Networks», *J. Med. Imaging Health Inform.*, vol. 10, n.º 3, pp. 758-762, mar. 2020, doi: 10.1166/jmhi.2020.2929.
- [104] M. Yang y J. Wang, «Adaptability of Financial Time Series Prediction Based on BiLSTM», *Procedia Comput. Sci.*, vol. 199, pp. 18-25, ene. 2022, doi: 10.1016/j.procs.2022.01.003.
- [105] A. Graves y J. Schmidhuber, «Framewise phoneme classification with bidirectional LSTM networks», en *Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005.*, jul. 2005, pp. 2047-2052 vol. 4. doi: 10.1109/IJCNN.2005.1556215.
- [106] Y.-H. Li, L. N. Harfiya, K. Purwandari, y Y.-D. Lin, «Real-Time Cuffless Continuous Blood Pressure Estimation Using Deep Learning Model», *Sensors*, vol. 20, n.º 19, Art. n.º 19, ene. 2020, doi: 10.3390/s20195606.
- [107] Z. Cui, R. Ke, Z. Pu, y Y. Wang, «Deep Bidirectional and Unidirectional LSTM Recurrent Neural Network for Network-wide Traffic Speed Prediction», 23 de noviembre de 2019, *arXiv*: arXiv:1801.02143. doi: 10.48550/arXiv.1801.02143.
- [108] K. Zarzycki y M. Ławryńczuk, «Advanced predictive control for GRU and LSTM networks», *Inf. Sci.*, vol. 616, pp. 229-254, nov. 2022, doi: 10.1016/j.ins.2022.10.078.
- [109] R. Rouhi Ardehshiri y C. Ma, «Multivariate gated recurrent unit for battery remaining useful life prediction: A deep learning approach», *Int. J. Energy Res.*, vol. 45, n.º 11, pp. 16633-16648, 2021, doi: 10.1002/er.6910.
- [110] X. Yan, H. Liu, Z. Zhu, y Q. Wu, «Hybrid genetic algorithm for engineering design problems», *Clust. Comput.*, vol. 20, n.º 1, pp. 263-275, mar. 2017, doi: 10.1007/s10586-016-0680-8.
- [111] S. Chen y C. Zhou, «Stock Prediction Based on Genetic Algorithm Feature Selection and Long Short-Term Memory Neural Network», *IEEE Access*, vol. 9, pp. 9066-9072, 2021, doi: 10.1109/ACCESS.2020.3047109.
- [112] P. Wide y H. Schellwat, «Implementation of a genetic algorithm for routing an autonomous robot», *Robotica*, vol. 15, n.º 2, pp. 207-211, mar. 1997, doi: 10.1017/S0263574797000222.
- [113] S. Katoch, S. S. Chauhan, y V. Kumar, «A review on genetic algorithm: past, present, and future», *Multimed. Tools Appl.*, vol. 80, n.º 5, pp. 8091-8126, feb. 2021, doi: 10.1007/s11042-020-10139-6.
- [114] K. Deb, «An introduction to genetic algorithms», *Sadhana*, vol. 24, n.º 4, pp. 293-315, ago. 1999, doi: 10.1007/BF02823145.
- [115] K. F. Pál, «Genetic algorithm with local optimization», *Biol. Cybern.*, vol. 73, n.º 4, pp. 335-341, sep. 1995, doi: 10.1007/BF00199469.
- [116] M. Marseguerra, E. Zio, y L. Podofillini, «Model parameters estimation and sensitivity by genetic algorithms», *Ann. Nucl. Energy*, vol. 30, n.º 14, pp. 1437-1456, sep. 2003, doi: 10.1016/S0306-4549(03)00083-5.

- [117] U. Depczynski, V. J. Frost, y K. Molt, «Genetic algorithms applied to the selection of factors in principal component regression», *Anal. Chim. Acta*, vol. 420, n.º 2, pp. 217-227, sep. 2000, doi: 10.1016/S0003-2670(00)00893-X.
- [118] G. Joshi y M. B. Krishna, «Solving system of non-linear equations using Genetic Algorithm», en *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, sep. 2014, pp. 1302-1308. doi: 10.1109/ICACCI.2014.6968423.
- [119] D. A. Diver, «Applications of genetic algorithms to the solution of ordinary differential equations», *J. Phys. Math. Gen.*, vol. 26, n.º 14, p. 3503, jul. 1993, doi: 10.1088/0305-4470/26/14/017.
- [120] P. Seoane, M. Gestal, y J. Dorado, «Approach for solving multimodal problems using Genetic Algorithms with Grouped into Species optimized with Predator-Prey», jun. 2012, doi: 10.9781/ijimai.2012.151.
- [121] B. Lampe y W. Meng, «A survey of deep learning-based intrusion detection in automotive applications», *Expert Syst. Appl.*, vol. 221, p. 119771, jul. 2023, doi: 10.1016/j.eswa.2023.119771.
- [122] S. F. Ramli, M. Firdaus, H. Uzair, y A. Zharif, «Prediction of the unemployment rate in Malaysia», *Int. J. Mod. Trends Soc. Sci. IJMTSS*, vol. 1, n.º 4, Art. n.º 4, 2018, Accedido: 3 de noviembre de 2024. [En línea]. Disponible en: <https://gaexcellence.com/ijmtss/article/view/648>
- [123] J. P. Arellano Estrada, «Determinantes del desempleo en el Ecuador, periodo 2003-2018», bachelorThesis, Universidad Nacional de Chimborazo, 2019, Ecuador, Riobamba, 2019. Accedido: 3 de noviembre de 2024. [En línea]. Disponible en: <http://dspace.unach.edu.ec/handle/51000/5855>
- [124] S. Göktepe Yıldız y S. Göktepe Körpeoğlu, «Prediction of students' perceptions of problem solving skills with a neuro-fuzzy model and hierarchical regression method: A quantitative study», *Educ. Inf. Technol.*, vol. 28, n.º 7, pp. 8879-8917, jul. 2023, doi: 10.1007/s10639-022-11446-1.
- [125] D. Peral-García, J. Cruz-Benito, y F. J. García-Peñalvo, «Systematic literature review: Quantum machine learning and its applications», *Comput. Sci. Rev.*, vol. 51, p. 100619, feb. 2024, doi: 10.1016/j.cosrev.2024.100619.
- [126] D. H. Autor y D. Dorn, «The Growth of Low-Skill Service Jobs and the Polarization of the US Labor Market», *Am. Econ. Rev.*, vol. 103, n.º 5, pp. 1553-1597, ago. 2013, doi: 10.1257/aer.103.5.1553.
- [127] O. Claveria, «Forecasting the unemployment rate using the degree of agreement in consumer unemployment expectations», *J. Labour Mark. Res.*, vol. 53, n.º 1, p. 3, feb. 2019, doi: 10.1186/s12651-019-0253-4.
- [128] M. Yang y J. Wang, «Adaptability of Financial Time Series Prediction Based on BiLSTM», *Procedia Comput. Sci.*, vol. 199, pp. 18-25, ene. 2022, doi: 10.1016/j.procs.2022.01.003.
- [129] Y. Zhang, W. Shang, N. Zhang, X. Pan, y B. Huang, «Quarterly GDP forecast based on coupled economic and energy feature WA-LSTM model», *Front. Energy Res.*, vol. 11, nov. 2023, doi: 10.3389/fenrg.2023.1329376.
- [130] X. Wu, Z. Zhang, H. Chang, y Q. Huang, «A Data-Driven Gross Domestic Product Forecasting Model Based on Multi-Indicator Assessment», *IEEE Access*, vol. 9, pp. 99495-99503, 2021, doi: 10.1109/ACCESS.2021.3062671.
- [131] M. S. Solmaz y M. T. Sanjani, «How External Factors Affect Domestic Economy: Nowcasting an Emerging Market», *IMF Work. Pap.*, Art. n.º 2015/269, dic. 2015, Accedido: 21 de enero de 2025. [En línea]. Disponible en: <https://ideas.repec.org//p/imf/imfwpa/2015-269.html>

- [132] M. Yurtsever, «Unemployment Rate Forecasting: LSTM-GRU Hybrid Approach», *J. Labour Mark. Res.*, vol. 57, n.º 1, Art. n.º 1, jun. 2023, doi: 10.1186/s12651-023-00345-8.
- [133] A. Vosseler y E. Weber, «Forecasting seasonal time series data: a Bayesian model averaging approach», *Comput. Stat.*, vol. 33, n.º 4, Art. n.º 4, dic. 2018, doi: 10.1007/s00180-018-0801-3.
- [134] F. Ahmmed Mohammed, «Applying Hybrid time series models for modeling bivariate time series data with different distributions for forecasting unemployment rate in the USA», *J. Mech. Contin. Math. Sci.*, vol. 14, n.º 5, Art. n.º 5, oct. 2019, doi: 10.26782/jmcms.2019.10.00026.
- [135] A. A. Davidescu, S.-A. Apostu, y A. Paul, «Comparative Analysis of Different Univariate Forecasting Methods in Modelling and Predicting the Romanian Unemployment Rate for the Period 2021-2022», *Entropy*, vol. 23, n.º 3, Art. n.º 3, mar. 2021, doi: 10.3390/e23030325.
- [136] N. Ramli, S. M. Ab Mutalib, y D. Mohamad, «Fuzzy Time Series Forecasting Model with Natural Partitioning Length Approach for Predicting the Unemployment Rate under Different Degree of Confidence», en *Proceedings of the 24th National Symposium on Mathematical Sciences (sksm24): Mathematical Sciences Exploration for the Universal Preservation*, Z. Salleh, R. Hasni, G. Rudrusamy, M. S. Lola, H. Salleh, H. A. Rahim, y M. AbdJalil, Eds., Melville: Amer Inst Physics, 2017, p. 040026. doi: 10.1063/1.4995858.
- [137] Y. Zhang, W. Shang, N. Zhang, X. Pan, y B. Huang, «Quarterly GDP forecast based on coupled economic and energy feature WA-LSTM model», *Front. Energy Res.*, vol. 11, nov. 2023, doi: 10.3389/fenrg.2023.1329376.
- [138] J. Vrbka, «Predicting Future GDP Development by Means of Artificial Intelligence», *Littera Scr.*, vol. 9, n.º 3, 2016.
- [139] G. Cicceri, G. Inserra, y M. Limosani, «A Machine Learning Approach to Forecast Economic Recessions—An Italian Case Study», *Mathematics*, vol. 8, n.º 2, Art. n.º 2, feb. 2020, doi: 10.3390/math8020241.
- [140] S.-L. Lin, «Application of empirical mode decomposition to improve deep learning for US GDP data forecasting», *Heliyon*, vol. 8, n.º 1, ene. 2022, doi: 10.1016/j.heliyon.2022.e08748.
- [141] Y. Gu, Z. Shao, X. Huang, y B. Cai, «GDP Forecasting Model for China's Provinces Using Nighttime Light Remote Sensing Data», *Remote Sens.*, vol. 14, n.º 15, Art. n.º 15, ene. 2022, doi: 10.3390/rs14153671.
- [142] O. Claveria, E. Monte, y S. Torra, «A Genetic Programming Approach for Economic Forecasting with Survey Expectations», *Appl. Sci.*, vol. 12, n.º 13, Art. n.º 13, ene. 2022, doi: 10.3390/app12136661.
- [143] N. Price y P. M. Atkinson, «Global GDP Prediction With Night-Lights and Transfer Learning», *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 15, pp. 7128-7138, 2022, doi: 10.1109/JSTARS.2022.3200754.
- [144] Y. Ye, S. Xu, M. S. Mariani, y L. Lü, «Forecasting countries' gross domestic product from patent data», *Chaos Solitons Fractals*, vol. 160, p. 112234, jul. 2022, doi: 10.1016/j.chaos.2022.112234.
- [145] M. Mogliani y A. Simoni, «Bayesian MIDAS penalized regressions: Estimation, selection, and prediction», *J. Econom.*, vol. 222, n.º 1, Part C, pp. 833-860, may 2021, doi: 10.1016/j.jeconom.2020.07.022.
- [146] M. Qiu *et al.*, «Huizhou GDP forecast based on fractional opposite-direction accumulating nonlinear grey bernoulli markov model», *Electron. Res. Arch.*, vol. 31, n.º 2, Art. n.º era-31-02-047, 2023, doi: 10.3934/era.2023047.

- [147] Z. Liu, J. Liu, X. Huang, E. Zhang, y B. Chen, «Measuring Chinese cities' economic development with mobile application usage», *J. Geogr. Sci.*, vol. 32, n.º 12, pp. 2415-2429, feb. 2022, doi: 10.1007/s11442-022-2054-x.
- [148] D. Alaminos, M. B. Salas, y M. A. Fernández-Gámez, «Quantum Computing and Deep Learning Methods for GDP Growth Forecasting», *Comput. Econ.*, vol. 59, n.º 2, pp. 803-829, feb. 2022, doi: 10.1007/s10614-021-10110-z.
- [149] A. M. Rahmani y S. Y. Hosseini Mirmahaleh, «An Intelligent Algorithm to Predict GDP Rate and Find a Relationship Between COVID-19 Outbreak and Economic Downturn», *Comput. Econ.*, vol. 63, n.º 3, pp. 1001-1020, mar. 2024, doi: 10.1007/s10614-022-10332-9.
- [150] X. Gui, M. Fečkan, y J. R. Wang, «The application of PSO-BP combined model and GA-BP combined model in Chinese and V4's economic growth model», *J. Appl. Math. Stat. Inform.*, vol. 18, n.º 2, pp. 33-56, dic. 2022, doi: 10.2478/jamsi-2022-0011.
- [151] M. Wozniak, «Forecasting the unemployment rate over districts with the use of distinct methods», *Stud. Nonlinear Dyn. Econom.*, vol. 24, n.º 2, p. 20160115, abr. 2020, doi: 10.1515/snde-2016-0115.
- [152] N. Ramli, S. M. Ab Mutalib, y D. Mohamad, «Fuzzy Time Series Forecasting Model with Natural Partitioning Length Approach for Predicting the Unemployment Rate under Different Degree of Confidence», en *Proceedings of the 24th National Symposium on Mathematical Sciences (sksm24): Mathematical Sciences Exploration for the Universal Preservation*, Z. Salleh, R. Hasni, G. Rudrusamy, M. S. Lola, H. Salleh, H. A. Rahim, y M. AbdJalil, Eds., Melville: Amer Inst Physics, 2017, p. 040026. doi: 10.1063/1.4995858.
- [153] E. Olmedo, «Forecasting Spanish Unemployment Using Near Neighbour and Neural Net Techniques», *Comput. Econ.*, vol. 43, n.º 2, pp. 183-197, feb. 2014, doi: 10.1007/s10614-013-9371-1.
- [154] W. Deng, G. Wang, X. Zhang, J. Xu, y G. Li, «A multi-granularity combined prediction model based on fuzzy trend forecasting and particle swarm techniques», *Neurocomputing*, vol. 173, pp. 1671-1682, ene. 2016, doi: 10.1016/j.neucom.2015.09.040.
- [155] F. Ahmmed Mohammed, «Applying Hybrid time series models for modeling bivariate time series data with different distributions for forecasting unemployment rate in the USA», *J. Mech. Contin. Math. Sci.*, vol. 14, n.º 5, oct. 2019, doi: 10.26782/jmcmcs.2019.10.00026.
- [156] T.-T. Nguyen, H.-G. Nguyen, J.-Y. Lee, Y.-L. Wang, y C.-S. Tsai, «The Consumer Price Index Prediction Using Machine Learning Approaches: Evidence from the United States», *Heliyon*, vol. 9, n.º 10, p. e20730, oct. 2023, doi: 10.1016/j.heliyon.2023.e20730.
- [157] D. P. Neghab, M. Cevik, M. I. M. Wahab, y A. Basar, «Explaining Exchange Rate Forecasts with Macroeconomic Fundamentals Using Interpretive Machine Learning», *Comput. Econ.*, may 2024, doi: 10.1007/s10614-024-10617-1.
- [158] R. Mattera, M. Misuraca, G. Scepi, y M. Spano, «A Mixed-Frequency Approach for Exchange Rate Predictions», *Electron. J. Appl. Stat. Anal.*, vol. 14, n.º 1, Art. n.º 1, may 2021, doi: 10.1285/i20705948v14n1p230.
- [159] M. Z. Abedin, M. H. Moon, M. K. Hassan, y P. Hajek, «Deep learning-based exchange rate prediction during the COVID-19 pandemic», *Ann. Oper. Res.*, nov. 2021, doi: 10.1007/s10479-021-04420-6.
- [160] A. Kartono, M. Febriyanti, S. T. Wahyudi, y Irmansyah, «Predicting foreign currency exchange rates using the numerical solution of the incompressible Navier–Stokes equations», *Phys. Stat. Mech. Its Appl.*, vol. 560, p. 125191, dic. 2020, doi: 10.1016/j.physa.2020.125191.
- [161] R. Hua, W. Hu, y X. Zhao, «Research on RMB exchange rate forecast based on the neural network model and the Nelson–Siegel model», *Risk Manage.*, vol. 22, n.º 3, pp. 219-237, sep. 2020, doi: 10.1057/s41283-020-00062-3.

- [162] T. N. Pandey, A. K. Jagadev, S. Dehuri, y S.-B. Cho, «A novel committee machine and reviews of neural network and statistical models for currency exchange rate prediction: An experimental analysis», *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 32, n.º 9, pp. 987-999, nov. 2020, doi: 10.1016/j.jksuci.2018.02.010.
- [163] A. Yağmur, Z. Karaçor, F. Mangır, y A. B. Yussif, «PREDICTING USD/ TL EXCHANGE RATE IN TURKEY: THE LONG-SHORT TERM MEMORY APPROACH», *J. Mehmet Akif Ersoy Univ. Econ. Adm. Sci. Fac.*, vol. 10, n.º 2, Art. n.º 2, ago. 2023, doi: 10.30798/makuiibf.1097568.
- [164] C. Hu, K. Zheng, y L. Liu, «Layered Exchange Rate Prediction Model Based on LSTM», en *Proceedings of the 2020 5th International Conference on Mathematics and Artificial Intelligence*, en ICMAI '20. New York, NY, USA: Association for Computing Machinery, may 2020, pp. 124-127. doi: 10.1145/3395260.3395288.
- [165] A. Kartono, S. Solekha, T. Sumaryada, y Irmansyah, «Foreign currency exchange rate prediction using non-linear Schrödinger equations with economic fundamental parameters», *Chaos Solitons Fractals*, vol. 152, p. 111320, nov. 2021, doi: 10.1016/j.chaos.2021.111320.
- [166] M. Jannová y P. Rousek, «Predicting the euro to Czech crown exchange rate», *Ad Alta - J. Interdiscip. Res.*, n.º 1, 2023, Accedido: 11 de agosto de 2024. [En línea]. Disponible en: <https://www.magnanimitas.cz/13-01>
- [167] Y. E. Midilli y S. Parsutins, «Optimization of Deep Learning Hyperparameters with Experimental Design in Exchange Rate Prediction», en *2020 61st International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS)*, oct. 2020, pp. 1-4. doi: 10.1109/ITMS51158.2020.9259300.
- [168] A. Biswas, I. A. Uday, K. M. Rahat, M. S. Akter, y M. R. C. Mahdy, «Forecasting the United State Dollar(USD)/Bangladeshi Taka (BDT) exchange rate with deep learning models: Inclusion of macroeconomic factors influencing the currency exchange rates», *PLOS ONE*, vol. 18, n.º 2, p. e0279602, feb. 2023, doi: 10.1371/journal.pone.0279602.
- [169] Q. Peng, J. Li, Y. Zhao, y H. Wu, «The Informational Content of Implied Volatility: Application to the USD/JPY Exchange Rates», *J. Asian Econ.*, vol. 76, p. 101363, oct. 2021, doi: 10.1016/j.asieco.2021.101363.
- [170] G. Wang, J. Ma, Y. Wang, T. Tao, G. Ren, y H. Zhu, «SUDF-RS: A new foreign exchange rate prediction method considering the complementarity of supervised and unsupervised deep representation features», *Expert Syst. Appl.*, vol. 214, p. 119152, mar. 2023, doi: 10.1016/j.eswa.2022.119152.
- [171] M.-J. Chang y T. Matsuki, «Exchange rate forecasting with real-time data: Evidence from Western offshoots», *Res. Int. Bus. Finance*, vol. 59, p. 101538, ene. 2022, doi: 10.1016/j.ribaf.2021.101538.
- [172] K. K. Sahu, S. C. Nayak, y H. S. Behera, «Forecasting currency exchange rate time series with fireworks-algorithm-based higher order neural network with special attention to training data enrichment», *Comput. Sci.*, vol. 21, n.º 4, Art. n.º 4, nov. 2020, doi: 10.7494/csci.2020.21.4.3474.
- [173] H. Xu, C. Xu, Y. Sun, J. Peng, W. Tian, y Y. He, «Exchange Rate Forecasting Based on Integration of Gated Recurrent Unit (GRU) and CBOE Volatility Index (VIX)», *Comput. Econ.*, oct. 2023, doi: 10.1007/s10614-023-10484-2.
- [174] M.-L. Shen, C.-F. Lee, H.-H. Liu, P.-Y. Chang, y C.-H. Yang, «An Effective Hybrid Approach for Forecasting Currency Exchange Rates», *Sustainability*, vol. 13, n.º 5, Art. n.º 5, ene. 2021, doi: 10.3390/su13052761.
- [175] M. Asadullah, A. Bashir, y A. R. Aleemi, «Forecasting Exchange Rates: An Empirical Application to Pakistani Rupee», *J. Asian Finance Econ. Bus.*, vol. 8, n.º 4, pp. 339-347, 2021, doi: 10.13106/jafeb.2021.vol8.no4.0339.

- [176] M. M. Panda, S. N. Panda, y P. K. Pattnaik, «Forecasting Foreign Currency Exchange Rate using Convolutional Neural Network», *Int. J. Adv. Comput. Sci. Appl. IJACSA*, vol. 13, n.º 2, Art. n.º 2, 51/28 2022, doi: 10.14569/IJACSA.2022.0130272.
- [177] G. Wang, T. Tao, J. Ma, H. Li, H. Fu, y Y. Chu, «An improved ensemble learning method for exchange rate forecasting based on complementary effect of shallow and deep features», *Expert Syst. Appl.*, vol. 184, p. 115569, dic. 2021, doi: 10.1016/j.eswa.2021.115569.
- [178] H. Yasar y Z. H. Kilimci, «US Dollar/Turkish Lira Exchange Rate Forecasting Model Based on Deep Learning Methodologies and Time Series Analysis», *Symmetry*, vol. 12, n.º 9, Art. n.º 9, sep. 2020, doi: 10.3390/sym12091553.
- [179] E. A. A. Wazeer y L. M. A. Hameed, «Forecasting the Exchange Rates of the Us Dollar Against the Iraqi Dinar Using the Box-Jenkins Methodology in Time Series with Practical Application», *Int. J. Agric. Stat. Sci.*, vol. 17, pp. 2085-2093, 2021.
- [180] H. K. CHOW, «FORECASTING INFLATION WITH A FINANCIAL CONDITIONS INDEX: THE CASE OF SINGAPORE», *Ann. Financ. Econ.*, ene. 2014, doi: 10.1142/S2010495213500097.
- [181] D. Mitra y M. Rashid, «Comparative accuracy of forecasts of inflation: a Canadian study», *Appl. Econ.*, vol. 28, n.º 12, pp. 1633-1637, dic. 1996, doi: 10.1080/000368496327606.
- [182] D. Ferreira y A. A. Palma, «Forecasting Inflation with the Phillips Curve: A Dynamic Model Averaging Approach for Brazil», *Rev. Bras. Econ.*, vol. 69, pp. 451-465, dic. 2015, doi: 10.5935/0034-7140.20150021.
- [183] M. Simionescu, «Quarterly inflation rate target and forecasts in Romania», *Econ. Manag. Sustain.*, vol. 1, n.º 1, Art. n.º 1, dic. 2016, doi: 10.14254/jems.2016.1-1.1.

Apéndice A. Estudios para la predicción del PIB

Autores	Problema abordado	Conjunto de datos	Modelo propuesto	Configuración experimental	Resultados obtenidos
Marković D. et al. [23]	Pronóstico de la tasa de crecimiento o del producto interno bruto (PIB) en la Unión Europea.	Se utilizaron diez parámetros de ciencia y tecnología como datos de entrada para la predicción del PIB. Los datos procedían de 28 países de la Unión Europea.	<ul style="list-style-type: none"> - Máquina de aprendizaje extremo (ELM) - Programación genética (GP) - Red neuronal artificial (ANN) - Lógica difusa. 	El algoritmo ELM se aplica en redes de alimentación directa de una sola capa oculta (SLFN). Esta red tiene tres capas. La capa de entrada adquiere parámetros de entrada y los envía a la capa oculta. La capa oculta tiene nodos ocultos y función de activación. Existen vectores de peso entre la capa oculta y la capa de salida. ELM se aplica para predecir el crecimiento del PIB utilizando factores de ciencia y tecnología como entradas, y se compara su desempeño con los métodos de aprendizaje automático ANN, GP y lógica difusa.	ELM es superior a los otros métodos (ANN, GP y Fuzzy) en la predicción del crecimiento del PIB.
Stevanović M. et al. [50]	Estimación del producto interno bruto en la Unión Europea.	Para la estimación del PIB se utilizaron diferentes fuentes de electricidad (fuentes renovables, carbón y nucleares) que se refieren a los insumos utilizados para generar electricidad. Los datos se utilizaron para la Unión Europea de la base de datos del Banco Mundial.	- Red neuronal artificial (ANN).	Se examinó la relación entre el PIB y la utilización de electricidad en la Unión Europea. Se aplicó una ANN como metodología para la estimación de la tasa del PIB según la utilización de electricidad. La red ANN fue entrenada con dos algoritmos de entrenamiento, un método de aprendizaje extremo y un algoritmo de retropropagación para producir los mejores resultados de predicción del PIB.	El modelo ANN con método de aprendizaje extremo podría producir una predicción aceptable del PIB basada en la utilización de electricidad.

Marjanović V. et al. [51]	Predecir el PIB en función de las emisiones de dióxido de carbono (CO ₂) en la Unión Europea.	El conjunto de datos se tomó de la base de datos del Banco Mundial para los países de la Unión Europea. Se analizan las emisiones de CO ₂ para el consumo de combustibles gaseosos, líquidos y sólidos. Como salida se utilizó la tasa de crecimiento del PIB real.	<ul style="list-style-type: none"> - Máquina de aprendizaje extremo (ELM). - Programación genética (GP). - Red neuronal artificial (ANN). 	Se aplicó la ELM, para modelar la relación entre las emisiones de CO ₂ y el crecimiento del PIB. La ELM se eligió por su facilidad de uso, velocidad de aprendizaje rápida y buen rendimiento de generalización. El tiempo medio de cálculo para el modelado ELM fue de unos 330 s utilizando un PC con CPU Intel Core Duo E7600 y 2 GB de RAM.	Los resultados muestran que la ELM logra un coeficiente de determinación (R ²) de 0.9271, lo que indica una alta precisión en la predicción del crecimiento del PIB en comparación con ANN (R ² = 0.8756) y GP (R ² = 0.4475). Además, se realizó un análisis de sensibilidad para identificar los parámetros más influyentes en la predicción del PIB, donde se encontró que las emisiones de CO ₂ provenientes del consumo de combustibles sólidos tienen la mayor influencia. Se demuestra que ELM se puede utilizar eficazmente en aplicaciones de previsión del PIB.
Li Q. et al. [72]	Predicción del PIB de tres provincias China: Shandong, Shanghai y Guangdon g.	<p>Se utilizan 20 indicadores relacionados con el PIB como características de predicción, que cubren cuatro aspectos: economía, población y empleo, industria y educación.</p> <p>Se utilizan tres conjuntos de datos de tres provincias de China para establecer un análisis experimental. El conjunto de datos contiene principalmente datos trimestrales del PIB de tres provincias de 2005 a 2021.</p>	Marco de decisión conjunto de múltiples predictores basado en el aprendizaje por refuerzo profundo.	En primer lugar, Gated Recurrent Unit (GRU), Temporal Convolutional Network (TCN) y Deep Belief Network (DBN) son los principales predictores para entrenar tres modelos de pronóstico del PIB con sus características. Luego, el algoritmo DQN analiza eficazmente la adaptabilidad de estas tres redes neuronales a diferentes conjuntos de datos del PIB para obtener un modelo conjunto. Finalmente, mediante la optimización adaptativa de los coeficientes de ponderación del conjunto de estas tres redes neuronales, el algoritmo DQN obtuvo los resultados finales de la predicción del PIB.	El marco de predicción del PIB regional de múltiples predictores basado en el aprendizaje por refuerzo profundo puede lograr mejores resultados de predicción que 18 modelos de referencia.
Xu X. et al. [73]	Predicción del PIB anual para	Emisiones de CO ₂ y el PIB anual de 1960 a	- Extreme Learning Machine with	La configuración experimental ELM-ABC implica configurar los	El modelo ELM-ABC tenía una gran capacidad de

	<p>cuatro países miembros principales de la Organización de Cooperación de Shanghai (SCO): China, Rusia, India y Pakistán.</p>	<p>2014 de los principales miembros de la SCO.</p>	<p>Artificial Bee Colony (ELM-ABC). - Echo State Network (ESN). - Support Vector Regression (SVR). - Extreme Learning Machine (ELM). - Kernel Extreme Learning Machine (KELM).</p>	<p>sets de entrenamiento y test, la definición de parámetros, la comparación de modelos, la validación cruzada para la evaluación del desempeño, la determinación del valor de idoneidad para la optimización y la aplicación del modelo ELM-ABC para el pronóstico de múltiples pasos. - Debido a la planificación estratégica nacional que se realiza a 5 o 10 años en desarrollo a corto o largo plazo, con el fin de entrenar un modelo para pronosticar la situación del PIB a largo plazo, se pueden utilizar los datos de emisiones de CO2 de diez años y los datos históricos del PIB de nueve años como características de entrenamiento, y el PIB del décimo año como valores objetivo se pueden utilizar para entrenar el modelo de predicción. Los datos de entrada y los valores objetivo se transforman mediante ecuaciones definidas (matriz transformada (T) y valores objetivos (Y)). - Definición del parámetro kernel (k) del modelo KELM en uno para los cuatro conjuntos de datos (de China, Rusia, India y Pakistán). - Comparar el modelo ELM-ABC con otros modelos para demostrar su capacidad superior. - Utilización de la validación cruzada Leave One Out (LOO) con el error porcentual absoluto medio simétrico (SMAPE) y el error cuadrático medio (MSE) para evaluar el rendimiento predictivo en todos los modelos. - Establecer el SMAPE promedio como el valor</p>	<p>pronóstico en la predicción del PIB y podía predecir el PIB anual futuro a diez años para los países correspondientes. La metodología ELM ABC es más sólida cuando la relación entre el PIB y las emisiones de CO2 es fuerte. Incluso, en la minoría de situaciones en las que esta relación no se mantiene (según la situación de Rusia), el modelo propuesto aún funcionó bien.</p>
--	--	--	--	---	--

				de aptitud de ABC para la optimización de parámetros - Emplear un algoritmo de predicción novedoso que utiliza ELM-ABC para realizar pronósticos de varios pasos después de entrenar el modelo.	
Zhang Y. et al. [137]	Pronóstico del PIB trimestral de China.	9 características económicas y 10 energéticas.	<ul style="list-style-type: none"> - Análisis wavelet con red neuronal de memoria a largo y corto plazo (WA-LSTM) - LSTM. - SARIMA. - 1D-CNN&WA. - 1D-CNN - ANN&WA. - ANN. - VAR&WA. - VAR. 	El estudio predice los datos trimestrales del PIB en China utilizando un modelo WA-LSTM de características económicas y energéticas acopladas. El estudio selecciona indicadores económicos específicos basados en la teoría de Keynes: el PIB real (PIB) trimestral, la oferta monetaria (M2), el monto finalizado de la inversión en activos fijos (INVERSIÓN), entre otros. Así mismo se seleccionan indicadores energéticos. El modelo emplea la red neuronal de memoria a largo y corto plazo (LSTM) combinada con el análisis wavelet (WA) para descomponer variables macroeconómicas y construir un modelo de predicción. La configuración experimental implica comparar el modelo LSTMWA con varios modelos de referencia como LSTM, 1D-CNN, ANN, SARIMA, entre otros, lo que muestra el rendimiento superior del modelo propuesto. La validación cruzada se utiliza para identificar parámetros o hiperparámetros para los modelos. El conjunto de datos original se divide en tres conjuntos: entrenamiento, validación y prueba. El método de validación cruzada de ventana móvil se emplea para seleccionar la mejor combinación de parámetros.	Al procesar datos estructuralmente complejos, no lineales y de múltiples variables, el modelo de predicción combinado de WA-LSTM demuestra mejores capacidades de generalización, y su precisión de predicción generalmente supera a otros modelos de referencia.

Li Q. et al. [22]	Predicción del PIB de China.	Se adopta los datos de tres provincias de China (Beijing, Hunan y Zhejiang) para construir el análisis experimental. Los datos provienen del Anuario Estadístico Nacional, que contiene datos del PIB y otros datos característicos para cada trimestre de 2005 a 2021. Los tipos de características son: Datos históricos del PIB, índices económicos históricos, características del empleo y la población, educación, características de la estructura industrial.	<ul style="list-style-type: none"> - Proposed model: FC-BorutarRF-Q-TCN - TCN - GRU - LSTM - RNN - ELM - RBF - FC-BorutaRF-PSO-TCN - FC-BorutaRF-GA-TCN - FC-BorutaRF-TCN - FC-Q-TCN - Yan's model, - Dong's model, - SVM. - ARIMA. 	El proceso de modelado central se compone principalmente de los siguientes tres pasos: En el Paso I, el algoritmo de cruce de características se utiliza para excavar en profundidad información de características ocultas de conjuntos de datos originales y extraer completamente información clave. En el Paso II, los algoritmos BorutaRF y Q-learning analizan la profunda correlación entre las características extraídas y los objetivos desde dos perspectivas diferentes y determinan las características con la mayor calidad. En el Paso III, las características seleccionadas se utilizan como entrada de TCN (red convolucional temporal) para construir un modelo de predicción del PIB y obtener resultados de predicción finales.	El marco de predicción del PIB (FC-BorutarRF-Q-TCN) ha logrado un mejor rendimiento de pronóstico que 14 modelos de referencia.
Ortega-Bastida J. et al. [74]	Predicción del PIB en España	El estudio utilizó conjuntos de datos de Twitter para cuatro regiones clave de España: Madrid, la Comunidad Valenciana, Andalucía y Murcia. Cada conjunto contenía tweets relacionados con el ámbito económico y etiquetados con los valores del PIB correspondientes al momento en que fueron escritos., abarcando el período de 2012 a 2016. Se descargaron 1500 tweets por trimestre y región, totalizando 120,000 tweets, 30,000 por cada región. Los datos del PIB regional hasta 2016 se obtuvieron del Instituto Universitario de Análisis Económico y Social (IAES) y se calcularon utilizando el modelo METCAP.	<ul style="list-style-type: none"> - Enfoque multimodal basado en Machine Learning (propuesta). - Seasonal Baseline - Método Vrbka (aplicación de redes neuronales: Red neuronal de la función básica radial (RBF), Perceptrón múltiple de red neuronal (MLP)) [138] - Método Cicceri et al. (aplicación de técnicas de estimación de regresión: Autoregressive (AR) model, Ordinary Least Squares regression (OLS), Nonlinear Autoregression models (NAR), Nonlinear Autoregressive with exogenous variables model (NARX), Support Vector Regression (SVR), 	El método propuesto se basa en una arquitectura de dos etapas. En la primera etapa, se utiliza inicialmente un codificador automático multitarea para obtener una representación de los tweets relacionada con el PIB, que luego se filtran para eliminar los valores atípicos y obtener la predicción del PIB a partir del consenso de opiniones. En una segunda etapa, este resultado se combina con los valores históricos del PIB de la región utilizando una red multimodal. Estas dos fuentes de información se combinan mediante un método multimodal para mejorar la predicción final. Se evaluaron varias topologías de red, bibliotecas de incrustación de palabras e hiperparámetros para obtener la mejor	<p>Los resultados muestran que el enfoque aprende con éxito la evolución del PIB utilizando únicamente información histórica y tweets, lo que permite proporcionar pronósticos más tempranos sobre el PIB regional.</p> <p>El método propuesto proporciona resultados significativamente mejores que los obtenidos por otros métodos del estado del arte, obteniendo una estimación más precisa incluso cuando el método se utiliza durante las primeras semanas del trimestre.</p>

			K-Nearest Neighbors (KNN), Boosted Trees (BT))[139].	configuración para el método propuesto. El método se evalúa en cuatro regiones diferentes de España a partir de los tuits escritos por los economistas, políticos, periódicos e instituciones más relevantes de cada una de ellas.	
Lin S.-L. [140]	Previsión de datos del PIB de EE. UU.	El conjunto de datos utilizado en la investigación son los datos de la tasa de crecimiento del PIB de EE. UU., obtenidos desde (https://fred.stlouisfed.org); el tamaño es 282 conjuntos de datos desde el 01-01-1948 hasta el 04-01-2018. Los datos de la tasa de crecimiento del PIB de EE. UU. se dividieron en dos partes: un conjunto de entrenamiento que consta de 254 conjuntos de datos del 01-01-1948 al 04-01-2011, y un conjunto de verificación que consta de 28 conjuntos de datos del 07-01-2011 al 04-01-2018.	- EMD + LSTM. (propuesta) - LSTM.	La configuración experimental implicó la aplicación del método de descomposición de modo empírico EMD para mejorar el aprendizaje profundo para pronosticar tendencias y predicciones de los datos del PIB de EE. UU. Para los experimentos se utilizaron los datos de la tasa de crecimiento del PIB de EE. UU., dividiéndose los datos en un conjunto de entrenamiento y un conjunto de verificación para el entrenamiento y las pruebas del modelo. El proceso de descomposición de los EMD implicó descomponer la tasa de crecimiento del PIB de Estados Unidos en funciones de modo intrínseco (FMI), incluidas FMI1 a FMI6 (residuo), para capturar componentes de series temporales de corto, mediano y largo plazo. Se empleó el modelo de memoria a largo y corto plazo (LSTM) para la predicción, y los datos descompuestos por EMD se utilizaron para mejorar la estabilidad y precisión del modelo propuesto.	Se compara el RMSE para los datos reales y los resultados previstos obtenidos con los dos métodos. El RMSE de EMD + LSTM es 0.93557, que es mejor que el RMSE previsto por LSTM de 2.7274.
Gu Y. et al. [141]	Modelo de previsión del PIB para las provincias de China: Beijing, Shanxi, Jilin, Jiangsu,	Datos históricos del Producto Interno Bruto (PIB) de 1992 a 2016 y datos anuales calibrados del "Programa de Satélites Meteorológicos de Defensa/ Sistema de Escaneo Lineal Operativo (DMSP/OLS)" de 1992 a 2013 y de la "Asociación	- Regresión Lineal (LR). - Modelo autorregresivo integrado de media móvil (ARIMA). - Modelo autorregresivo integrado de media	El método de este estudio sigue tres pasos principales: (1) calibración NTL; (2) predicción del PIB; y (3) evaluación de la precisión. (1) Calibración NTL: El proceso de calibración	Los resultados mostraron que el modelo ARIMAX logró el mejor resultado de predicción.

	<p>Fujian, Henan, Guangdong, Chongqing, Yunnan, Gansu y Xinjiang.</p>	<p><i>Nacional de Órbita Polar/Suite del Radiómetro de Imágenes Visible e Infrarrojo (NPP/VIIRS)</i> de 2012 a 2020 para construir una serie de datos de luz nocturna (NTL) consistente a nivel provincial de China, recuperada de la información ambiental nacional (https://www.ngdc.noaa.gov). Los datos del PIB se obtuvieron del Anuario Estadístico oficial de China.</p> <p>La combinación de estos conjuntos de datos permitió la construcción de un conjunto de datos integral que facilitó la previsión del PIB utilizando datos de teledetección de NTL.</p>	<p>móvil con variable explicativa (ARIMAX). - Modelo autorregresivo integrado de medias móviles estacional (SARIMA).</p>	<p>NTL involucró dos pasos principales: - <i>Paso 1. La calibración interna de los datos DMSP/OLS</i> tuvo como objetivo mejorar la calidad de las series temporales NTL obtenidas por este sensor satelital (DMSP/OLS), ya que son afectadas por errores sistemáticos y ruido aleatorio. - <i>Paso 2. La Calibración Cruzada de Sensores de DMSP/OLS y NPP/VIIRS</i> tiene como objetivo armonizar y hacer compatibles los datos NTL adquiridos por estos dos sensores satelitales (DMSP/OLS y NPP/VIIRS) diferentes.</p> <p>(2) Predicción del PIB: La predicción del PIB implicó la utilización de datos NTL calibrados junto con los registros del PIB para pronosticar el desarrollo económico en las provincias de China utilizando varios modelos como LR, ARIMA, ARIMAX y SARIMA.</p> <p>(3) Evaluación de la precisión: La evaluación tuvo como objetivo valorar el desempeño de los modelos de pronóstico y determinar el modelo que proporcionó las predicciones del PIB más precisas para las provincias de China, para lo que se usó la fórmula de error porcentual (r) que describe la diferencia relativa entre el PIB real y el previsto.</p>	
Shams M. et al. [64]	<p>Predicir el Producto Interno Bruto (PIB) en áreas de perfil urbano para cada país.</p>	<p>Este estudio emplea dos conjuntos de datos separados, denominados Conjunto de datos A y Conjunto de datos B. El conjunto de datos A comprende 227 instancias y 20 funciones, de las cuales el 70 % se utiliza para</p>	<p>- Correlación de Pearson - Memoria a largo y corto plazo - Red neuronal recurrente (PC-LSTM-RNN) - Correlación de Pearson- Regresión de Ridge (PC-RR).</p>	<p>El modelo PC LSTM RNN está diseñado para aprovechar las capacidades de retención de memoria de las LSTM y la secuencialidad de las RNN para capturar dependencias complejas en datos de series</p>	<p>Los resultados experimentales demostraron que el modelo PC-LSTM-RNN dio mejores resultados que los otros modelos de regresión, ya que el modelo</p>

		<p>capacitación y el 30 % con fines de prueba. Por otro lado, el conjunto de datos B consta de 61 instancias y 4 características, que abarcan datos históricos de crecimiento del PIB de la India desde 1961 hasta 2021.</p>	<ul style="list-style-type: none"> - Correlación de Pearson y Elastic Net (PC-EN). - Correlación de Pearson y regresión de Lasso (PC-Lasso). - Correlación de Pearson y potenciación del gradiente (PC-GB). - Correlación de Pearson y regresión K-vecinos más cercanos (PC-KNN). - Correlación de Pearson y Bosque aleatorio (PC-RF). 	<p>temporales, optimizando la precisión en la predicción del PIB de países mediante un enfoque de transferencia de parámetros y entrada secuencial de datos. El modelo se configuró con 3 capas, que son la puerta de olvido, la puerta de entrada y la puerta de salida, con 128 neuronas en cada capa. El tamaño del lote es 64, la tasa de aprendizaje es 0,001, el número de épocas es 50, el optimizador es Adam, los pasos de tiempo son 16 y la función de activación es la función de activación lineal. Las capas del bloque de memoria LSTM están completamente conectadas. Además, se utilizaron dos conjuntos de datos separados, denominados Conjunto de datos A y Conjunto de datos B, con fines de entrenamiento y prueba. El conjunto de datos A constaba de 227 instancias y 20 características, de las cuales el 70 % se utilizaba para capacitación y el 30 % para pruebas, mientras que el conjunto de datos B constaba de 61 instancias y 4 características, centrándose en datos históricos de crecimiento del PIB de la India de 1961 a 2021. En este estudio se realiza una etapa de preprocesamiento que incluye imputación de mediana y normalización de datos.</p>	<p>propuesto logra un R^2 de 99.99%.</p>
<p>Kumar S. et al. [70]</p>	<p>Desarrollar un algoritmo determinista basado en aprendizaje e intuicionista de</p>	<p>El conjunto de datos para el estudio involucró la predicción del PIB a partir de datos de emisiones de carbono, con datos del dominio fuente de la Unión Europea (UE) y datos del dominio objetivo de la India, recopilados de la</p>	<ul style="list-style-type: none"> - Aprendizaje intuicionista por transferencia difusa (IFTL). - Conjunto intervalo - valorado difuso (IVFS). - Máquina de aprendizaje extremo (ELM). 	<p>La configuración experimental del modelo IFTL se centró en la predicción del Producto Interno Bruto (PIB) a partir de datos de emisión de CO₂, motivada por la relación entre emisiones de carbono y desarrollo</p>	<p>IFTL aseguró mejoras significativas en la precisión de la predicción con respecto a otros enfoques existentes siempre que los datos de entrenamiento y</p>

	<p>transferencia difusa (IFTL) para estimar con precisión el PIB per cápita en el dominio de destino (India) utilizando datos de emisiones de CO₂.</p>	<p>base de datos del Banco Mundial.</p> <p>El estudio también consideró el uso de datos de EE. UU. como dominio de fuente alternativo para experimentos de aprendizaje de transferencia, donde este dominio fuente se utilizó también para predecir el PIB de la India como dominio objetivo.</p>	<p>- Máquina de vectores de soporte (SVM).</p> <p>- Red neuronal de regresión general (GRNN).</p>	<p>económico. Para los experimentos, se utilizó inicialmente el modelo de aprendizaje automático de Máquina de Aprendizaje Extremo (ELM) para la predicción de etiquetas en la Regresión Inconsciente del Objetivo (TUR). Posteriormente, se implementaron los modelos IFTL y de Aprendizaje por transferencia difusa (FTL), que utilizan las predicciones realizadas por GRNN y SVR como modelo TUR, para evaluar su desempeño en la refinación de etiquetas y mejora de la predicción del PIB.</p> <p>La evaluación se centró en la capacidad de estos modelos para mejorar el aprendizaje al incorporar un grado de hesitación en el proceso de transferencia de aprendizaje, logrando una reducción del RMSE entre el 10% y el 23%, y mejorando la precisión de las predicciones hasta un 22.9% en comparación con los modelos tradicionales.</p>	<p>prueba tengan enormes diferencias en la distribución de datos.</p>
Claveria O. et al [142]	<p>Estimaciones de las tasas de crecimiento interanual del PIB para 19 economías europeas.</p>	<p>La Encuesta Conjunta Armonizada de Consumidores de la UE realizada por la Comisión Europea, y las tasas de crecimiento interanual del PIB desestacionalizadas proporcionadas por Eurostat.</p>	<p>- Enfoque basado en la evolución de las expectativas (Evo.Exp).</p> <p>- Modelo de media móvil integrado autorregresivo (ARIMA).</p>	<p>En primer lugar, la programación genética se utiliza para hacer evolucionar las expectativas económicas de las empresas y los consumidores a fin de derivar indicadores de sentimiento para cada país. Para evaluar el desempeño de los indicadores propuestos, primero se diseñó un experimento de predicción inmediata en el que se generaron recursivamente estimaciones del PIB al final de cada trimestre, utilizando los últimos datos disponibles de encuestas de empresas y consumidores. En segundo lugar, diseñamos un ejercicio de pronóstico en el que</p>	<p>Los resultados demostraron que los indicadores de sentimiento evolucionados superaron a los modelos de referencia ARIMA para diferentes horizontes de pronóstico (h1, h12), destacando la efectividad del enfoque Evo.Exp para propósitos de pronóstico económico.</p>

				se recalculaba iterativamente los indicadores de sentimiento en cada período fuera de la muestra.	
Wu X et al. [75]	Predicción del PIB mensual para 26 provincias de China en 2016.	El conjunto de datos se construye con los datos recopilados del consumo de electricidad, el clima, la actividad humana y el PIB de 2010 a 2016.	PSO-LSTM.	El modelo PSO-LSTM se basa en la integración de la Red Neuronal de Memoria a Largo Plazo (LSTM) y el algoritmo de Optimización por Enjambre de Partículas (PSO). Para construir el modelo de pronóstico del Producto Interno Bruto (PIB), se seleccionan datos multidimensionales que incluyen consumo de electricidad, factores climáticos y actividad humana, utilizando la selección de características basada en la correlación. El LSTM se elige debido a su capacidad para manejar correlaciones temporales, mientras que el PSO se utiliza para optimizar los parámetros del LSTM, mejorando así la eficiencia computacional. En PSO, las partículas se actualizan iterativamente basándose en las mejores soluciones individuales y globales, lo que ayuda a converger hacia la solución óptima a lo largo del tiempo. La arquitectura del modelo incluye una capa de entrada con tres tipos de datos: consumo de electricidad, factores climáticos seleccionados (como temperatura media, humedad relativa media, y precipitación), y características provinciales (como el área de cada provincia y los datos de la población residente de fin de año). Estos datos, dentro de la capa oculta, pasan a través de dos capas LSTM y tres densas antes de fusionarse en una capa de concatenación,	La combinación de cinco factores que influyen (Consumo de electricidad (EC), temperatura media (AT), humedad relativa media (ARH), precipitación (PR) y nuevos usuarios de Weibo (NWU)) puede mejorar la precisión de la predicción en comparación con la predicción del PIB utilizando únicamente EC. La tasa de precisión promedio es del 96,28%.

				seguida de otra capa densa y finalmente una capa de salida que proporciona el pronóstico del PIB. La función de activación utilizada en las redes LSTM es la función tangente hiperbólica (tanh), que asigna datos de $(-\infty, +\infty)$ a $(-1, 1)$.	
Price N. and Atkinson P. [143]	Predicción del PIB global con luces nocturnas y aprendizaje por transferencia.	<p>Cifras del PIB del Banco Mundial: Estas cifras de PIB se obtuvieron de los datos de Cuentas Nacionales del Banco Mundial y de los archivos de datos de Cuentas Nacionales de la OCDE, y todas las cifras estaban en dólares estadounidenses corrientes para el 2019.</p> <p>VIIRS-DNB: Se utilizaron los datos de luces nocturnas de la banda día/noche (DNB) de Visible Infrarrojo Imaging Radiometer Suite (VIIRS), específicamente el producto promedio mensual de febrero de 2020. Este conjunto de datos incluye valores de radiancia nocturna promedio enmascarados y corregidos con una resolución espacial de aproximadamente 450 metros por cuadrado de cuadrícula. Para la Federación Rusa, se utilizó una resolución espacial más baja de aproximadamente 2700 metros por píxel debido a limitaciones de memoria.</p> <p>API de Google Static Maps Imágenes de sensores satelitales diurnos: Este conjunto de datos incluye imágenes de 224×224 px con una resolución espacial fina de aproximadamente 2.5 metros.</p> <p>Límites de los países del mundo: Para delimitar entre países, se utilizó el</p>	CNN basada en la arquitectura VGG-F.	El modelo utiliza el aprendizaje por transferencia para adaptar una CNN originalmente entrenada para la predicción de la pobreza a la predicción del PIB. Incorpora un enfoque de regionalización para manejar la heterogeneidad espacial y emplea muestreo de Monte Carlo para lograr escalabilidad. Los pasos de extracción de características, reducción de dimensionalidad y clasificación lineal juntos permiten predicciones precisas y eficientes del PIB utilizando datos de luces nocturnas e imágenes satelitales diurnas.	<p>El modelo logró un R^2 entre el PIB \log_{10} previsto y el real de 0.86 en el conjunto de validación y de 0.89 en toda el área de estudio.</p> <p>Superó a métodos comparables en un estudio subnacional realizado en 396 condados de EE. UU. utilizando 98.500 imágenes.</p>

		conjunto de datos (generalizado) de países del mundo [40] de Esri's. Este conjunto de datos proporciona límites precisos a grandes escalas cartográficas.			
Ye Y. et al. [144]	Pronóstico del producto interno bruto de los países a partir de datos de patentes.	Conjunto de datos de patentes de la Oficina Europea de Patentes (EPO) durante el período 1978-2015, que consta de 1,378,320 patentes y 885,721 citas.	<ul style="list-style-type: none"> - Esquema de previsibilidad selectiva en el plano HI-GDP (SPS_HG) (propuesta). - Fondo Monetario Internacional (IMF). - Esquema de previsibilidad selectiva en el plano fitness-GDP (SPS_FG). 	<p>La configuración experimental para SPS_HG implica la construcción de predicciones para el PIB per cápita de los países durante tres períodos de cinco años: 2008-2013, 2009-2014 y 2010-2015. El método SPS_HG se entrena utilizando datos de los diez años anteriores al período de predicción ($t - 10$ a t). Las predicciones se realizan utilizando el plano HI-GDP, que incorpora las métricas tecnológicas de los países (índice H) y el PIB per cápita. Las predicciones se filtran para incluir solo países con datos disponibles de los tres métodos en las tres ventanas, lo que da como resultado 223 casos pronosticados.</p> <p>Para evaluar la precisión de las predicciones, los resultados del método se comparan con dos líneas de base: IMF y SPS_FG. La comparación utiliza la tasa de crecimiento anual compuesta (CAGR) y evalúa los errores utilizando el error absoluto medio (MAE) y el error cuadrático medio (RMSE).</p>	El método SPS_HG demostró una tasa de error más baja que el FMI y un rendimiento ligeramente mejor que SPS_FG, destacando el valor predictivo de la centralidad tecnológica.
Mogliani M. and Simoni A. [145]	Pronóstico del crecimiento del PIB de EE. UU.	134 predictores reales y financieros muestreados con frecuencias mensuales, semanales y diarias.	<ul style="list-style-type: none"> - MIDAS bayesiano con grupo adaptativo Lasso (BMIDAS-AGL) - MIDAS bayesiano con grupo adaptativo Lasso y búsqueda estocástica (BMIDAS-AGL-SS) - MIDAS bayesiano con Lasso adaptativo (BMIDAS-AL) - Regresiones MIDAS penalizadas con Lasso (MIDAS-L), Elastic-Net 	La configuración implicó evaluar el rendimiento de muestras pequeñas de los modelos bayesianos de muestreo de datos mixtos (MIDAS) propuestos mediante simulaciones de Monte Carlo. El diseño de estos experimentos incluye un Proceso de Generación de Datos (DGP) con $k = \{30, 50\}$ predictores muestreados a una	Los modelos bayesianos MIDAS demostraron un rendimiento sólido en términos de estimación y selección de modelos en diferentes procesos de generación de datos (DGP). Específicamente, los modelos

			<p>(MIDAS-EN), SCAD (MIDAS-SCAD) y MC+ (MIDAS-MC+)</p> <ul style="list-style-type: none"> - AutoRegresivo de orden 1 (AR1) - Combinación de modelos MIDAS individuales Bayesianos (BMIDAS-comb) - Modelo Bayesiano Promediado con MIDAS (BMA-MIDAS) - Selección de Modelo Bayesiano con MIDAS (BMS-MIDAS) - MIDAS bayesiano de factor dinámico y factor objetivo (Factor-BMIDAS) - MIDAS bayesiano de factor dirigido con PCA y QML (t-Factor-BMIDAS) <p>Los modelos Factor-BMIDAS y t-Factor-BMIDAS usan análisis de componentes principales (PCA) y la estimación de verosimilitud cuasi máxima (QMLE) como métodos para la estimación de factores.</p>	<p>frecuencia $m = 3$ y $t = 200$ observaciones dentro de la muestra. La variable dependiente yt se modela en función de estos predictores, que están calculados mediante ponderaciones MIDAS normalizadas. Estos pesos siguen tres esquemas de ponderación alternativos: de decadencia rápida (DGP 1), de decadencia lenta (DGP 2) y casi plano (DGP 3).</p> <p>Los predictores $X_{kt}^{(m)}$ se generan con una estructura autorregresiva, incorporando correlación entre ellos. Los términos de ϵ_t y ε_t se distribuyen de forma independiente e idéntica, con una estructura de covarianza específica para controlar la correlación entre los predictores. Los parámetros para el DGP incluyen $\alpha = 0.5, \mu = 0.1, \rho = 0.9$ y $\beta = (0, 0.3, 0.5, 0, 0.3, 0.5, 0, 0, 0.8, 0)'$, asegurando que solo un subconjunto de predictores sea relevante. Las simulaciones se realizan con distintos grados de correlación entre los predictores para evaluar la solidez de los modelos. El muestreador de Gibbs se emplea para la estimación bayesiana, ejecutándose durante 300,000 iteraciones con un período de preparación, y el rendimiento de estimación y selección de los modelos se evalúa mediante métricas como el error cuadrático medio (MSE), la varianza y el sesgo al cuadrado.</p>	<p>fueron efectivos para estimar con precisión los coeficientes verdaderos y seleccionar los predictores relevantes, incluso en presencia de correlación entre los predictores y diversos grados de disminución de peso. Los resultados mostraron que los modelos funcionaron bien bajo diferentes esquemas de ponderación, enfatizando el sólido desempeño bajo DGP 1 (ponderaciones de rápida caída), lo que indica la capacidad de los modelos para manejar datos de alta frecuencia de manera eficiente.</p>
<p>Qiu M. et al. [146]</p>	<p>Pronóstico del PIB anual en la ciudad de Huizhou, China de</p>	<p>Datos históricos del PIB de los años 2017 a 2021.</p>	<p>- Modelo Bernoulli Markov gris no lineal de acumulación fraccional en dirección opuesta (FOANGBMKM (1,1)).</p>	<p>El modelo FOANGBMKM combina procesos de Bernoulli grises no lineales y de acumulación fraccional en dirección opuesta con</p>	<p>Los resultados muestran que el efecto de predicción del nuevo modelo propuesto</p>

	2017 a 2021.		<ul style="list-style-type: none"> - Modelo Autorregresivo Integrado de Media Móvil (ARIMA). - Modelo Bernoulli gris no lineal de acumulación fraccional en dirección opuesta (FOANGBM (1,1)). - Modelo Grey (GM (1,1)). - Modelo Bernoulli gris no lineal de acumulación fraccional (FANGBM (1,1)). 	un modelo de Markov para capturar las tendencias no lineales en los datos del PIB. Los parámetros del modelo se optimizan utilizando el algoritmo de optimización por enjambre de partículas (PSO). El modelo propuesto se aplica para pronosticar el PIB de la ciudad de Huizhou de 2017 a 2021.	FOANGBMKM (1,1) es mejor que el de los otros cuatro modelos competitivos.
Liu Z. et al. [147]	Predicción del PIB de las ciudades con MAUR.	<p>Registros de uso de aplicaciones móviles (MAUR), los MAUR se obtuvieron de un conjunto de datos de código abierto proporcionado por TalkingData.</p> <p>Datos estadísticos de las ciudades, incluido el PIB y el PIB per cápita, se obtuvieron del Anuario estadístico de ciudades chinas 2017 para 330 ciudades chinas.</p>	Modelo de regresión de árbol potenciado.	Inicialmente, los usuarios se dividen en grupos demográficos según género y edad, y se crea un vector de características multidimensional calculando el número de registros de uso de aplicaciones móviles (MAUR) para cada grupo. Se implementa un modelo de árbol de decisión potenciado con la biblioteca XGBoost, utilizando estos vectores como entrada. La diferencia entre las puntuaciones reales y las previstas se emplea para entrenar árboles posteriores, mejorando la precisión del modelo. Los hiperparámetros se ajustan mediante búsqueda en cuadrícula para garantizar un rendimiento óptimo. La eficacia del modelo se evalúa utilizando la métrica R^2 y un enfoque de validación cruzada de cinco pasos, que divide el conjunto de datos en cinco partes, promediando los resultados para obtener la evaluación final.	El modelo de regresión de árbol potenciado demuestra que logra una alta bondad de ajuste (más de $0.8 R^2$) y una buena precisión de predicción.
Alaminos D. et al [148]	Pronóstico del crecimiento del PIB para 70 países.	El período seleccionado es de 1980 a 2018 para una muestra de 70 países (47 países emergentes, 23 países desarrollados y una	Métodos de computación cuántica: Algoritmo de Murciélagu Cuántico de Regresión de	El modelo DNDT fue implementado utilizando una preparación de datos que dividió el conjunto en tres grupos exclusivos:	El modelo DNDT es el que mayores niveles de precisión ha obtenido. Los resultados son

		<p>muestra global de países).</p> <p>Los datos de las variables dependientes (crecimiento del PIB) e independientes (24 variables financieras y macroeconómicas) se obtuvieron de las Estadísticas Financieras Internacionales (IFS) del FMI y del Banco Mundial.</p>	<p>Vectores de Soporte (SVRQBA), Máquina de Boltzmann Cuántica (QBM) y Redes Neuronales Cuánticas (QNN)</p> <p>Métodos de aprendizaje profundo: Red Neuronal de Convolución Recurrente Profunda (DRCNN), Red de Creencia Profunda (DBN), Árboles de decisión neuronal profunda (DNDT) y Máquinas vectoriales de soporte lineal de aprendizaje profundo (DSVR).</p>	<p>entrenamiento (70%), validación (10%) y prueba (20%). Su arquitectura combina las ventajas de las redes neuronales profundas y los árboles de decisión, optimizando parámetros como el número de capas y neuronas basado en el rendimiento en el conjunto de validación. El modelo DNDT incluye una función de activación basada en una red neuronal (NN) definida por una ecuación softmax, que permite una codificación eficiente de la función de agrupamiento. Se utiliza el método Gumbel-Softmax Straight-Through para el muestreo de vectores cuando el factor de temperatura tiende a cero. Para construir el árbol de decisión, se emplea el producto de Kronecker, asociando cada característica de entrada con su red neuronal correspondiente, lo que permite determinar los nodos finales del árbol.</p> <p>El modelo asume que un clasificador lineal en cada hoja clasifica las instancias que llegan a esa hoja. El número de puntos de corte por característica se considera un parámetro de complejidad y no está limitado, permitiendo puntos de corte inactivos si están fuera del rango de los valores de las características. Esta configuración permite optimizar todos los parámetros mediante descenso de gradiente estocástico (SGD), facilitando el procesamiento a gran escala y el aprendizaje de extremo a extremo con retropropagación.</p>	<p>significativamente superiores a los obtenidos en la literatura existente, con un rango de precisión del 93,02 al 98,95 % para pronosticar el crecimiento del PIB.</p>
Rahmani A. M. and Hosseini	Predicción de la tasa de	El conjunto de datos recopilado consta de estadísticas de los	Redes neuronales (NNs).	Las arquitecturas se adaptaron a las necesidades específicas	Los resultados experimentales demuestran una

Mirmahaleh S. Y. [149]	desempleo en Alemania, India, Australia y Tailandia, y encontrar una relación entre el brote de COVID-19 y la recesión económica .	diferentes parámetros económicos y COVID-19 en los países mencionados en 2015-2020. Los datos de 2020 incluían tanto parámetros económicos como los nuevos casos de COVID-19. Las estadísticas económicas se recopilaron en las siguientes categorías: comercio, trabajo, PIB, precios, gobierno, vivienda, consumidor y dinero.		de cada país, la metodología de entrenamiento (aprendizaje supervisado, uso de la función de activación ReLU, entrenamiento con datos normalizados de 2020 y el método basado en la distancia de gradiente) se aplicó de manera uniforme en todos los países.	precisión de predicción de aproximadamente el 96 % y el 89 % durante uno o más meses, respectivamente.
Gui X. et al. [150]	Aplicación de modelos combinados PSO-BP y GA-BP del crecimiento del PIB de China y los países del Grupo de Visegrado (V4: República Checa, Hungría, Polonia y Eslovaquia).	Conjunto de datos compuesto por 7 variables explicativas. Estas variables explicativas son: - Superficie terrestre (LA). - Tierra cultivada (CL). - Población total (TP). - Exportación de bienes y servicios (EGS). - Importación de bienes y servicios (IGS). - Gasto de consumo final del gobierno general (FCEGG). - Formación bruta de capital (GCF). Los 26 datos descargados directamente del Banco Mundial fueron de 1995 a 2020.	- PSO-BP. - GA-BP. - Modelo Uniform-ini-BP. - Modelo Xavier-ini-BP. - Modelo de regresión multivariante.	El estudio se centró en la predicción del crecimiento del PIB en los países mencionados utilizando redes neuronales de propagación hacia atrás (BP) combinadas con algoritmos de optimización avanzados, como el Algoritmo de Optimización por Enjambre de Partículas (PSO) y el Algoritmo Genético (GA). Se recopilaron datos de 26 variables económicas del Banco Mundial para el período de 1995 a 2020, de los cuales se seleccionaron 7 variables explicativas clave para el análisis. Para el entrenamiento y prueba de las redes neuronales BP, los datos se dividieron en conjuntos de entrenamiento (70%), validación (15%) y prueba (15%). Se utilizaron dos modelos combinados: PSO-BP y GA-BP, los cuales optimizan los pesos y umbrales de las redes neuronales BP para mejorar la precisión en las predicciones. El proceso de entrenamiento incluyó la normalización de los datos y el ajuste iterativo de los parámetros del modelo	El modelo combinado PSO-BP en general tiene un error menor que otros en la predicción de los valores del PIB. Los resultados de predicción del modelo Uniform-ini-BP, el modelo Xavier-ini-BP y el modelo de regresión multivariante son deficientes.

				utilizando los algoritmos de optimización. La eficacia de estos modelos se comparó con modelos estándar de regresión multivariante y redes neuronales con diferentes métodos de inicialización (uniforme y Xavier), evaluando el rendimiento mediante métricas como el error cuadrático medio (MSE), desviación absoluta media (MAD), y el criterio de información bayesiano (BIC).	
--	--	--	--	---	--

Apéndice B. Estudios para la predicción de la tasa de desempleo

Autores	Problema abordado	Conjunto de datos	Modelo propuesto	Configuración experimental	Resultados obtenidos
Davidescu A. et al. [52, pp. 2021-2022]	Pronóstico de la tasa de desempleo rumana.	La tasa de desempleo mensual desde enero de 2000 hasta diciembre de 2020, obtenidos de la Encuesta de Población Activa de la Unión Europea (EU-LFS).	<ul style="list-style-type: none"> - Promedio móvil integrado autorregresivo estacional (SARIMA). - Umbral autorregresivo autoexcitante (SETAR). - Holt-Winters ETS (error, tendencia, estacional). - Autorregresión de redes neuronales (NNAR). 	La configuración experimental para el modelo Holt-Winters Multiplicative fue Smoothing parameters: Alpha (level) = 0.6928, Beta (trend) = 0.0001, Gamma (seasonal) = 0.0001, AIC = 630.187, AICc = 633.278 y BIC = 687.566. Para el modelo NNAR se utilizó la configuración NNAR(1,1,k) ₁₂ , donde k varía de 1 a 14 y para el modelo SARIMA la configuración SARIMA(0,1,6)(1,0,1) ₁₂ .	<p>Según los valores de RMSE y MAE, el modelo NNAR mostró un mejor desempeño de pronóstico. Según la métrica MAPE, el modelo SARIMA mostró una mayor precisión de pronóstico.</p> <p>Según la prueba de Diebold-Mariano el modelo NNAR es el mejor para modelar y pronosticar la tasa de desempleo.</p>
Vosseler A. and Weber E. [53]	Pronóstico de la tasa de desempleo en Alemania.	Conjunto de datos de tasas de desempleo mensuales no ajustadas de los 16 estados federales de Alemania, así como las series agregadas para Alemania Occidental y Oriental, durante el período de muestra de enero de 1991 a febrero de 2013	<ul style="list-style-type: none"> - Modelo bayesiano de promedio autorregresivo periódico (BMA-PAR). - Promedio móvil autorregresivo estacional (SARMA). - MEANS estacional (PMEANS) - PAR bayesiano (BPAR). 	En la configuración experimental se realizaron cinco experimentos de simulación para generar trayectorias y evaluar diferentes especificaciones de modelos, se utilizaron procesos estocásticos como PAR(1), SAR(1), SARMA(1,0)×(1,1), entre otros, con parámetros específicos para cada diseño de simulación y se comparó el modelo BMA-PAR con los modelos BPAR(1) y SARMA(0, 11) × (1, 0) ₁₂ .	<p>Los modelos PAR tienen ventajas en casos de raíces unitarias periódicas.</p> <p>La combinación de modelos BMA-PAR mejora la precisión predictiva en comparación con el modelo individual BPAR.</p>
Wozniak M. [151]	Pronóstico de la tasa de desempleo en la Gran Polonia.	Datos de panel mensuales para 35 LAU1s de Wielkopolska durante un período de 123 meses (de enero de 2005 a marzo de 2015), con un período de evaluación de 13 meses (de abril de 2015 a abril de 2016).	<ul style="list-style-type: none"> - Vectores autorregresivos (VAR). - Espacial VAR (VARs). - Redes neuronales (NN). - Redes neuronales estacionales (NNS). - Vectores autorregresivos espaciales (SpVAR). - Redes neuronales espaciales (SpNN). 	Los modelos espaciales se compararon con sus equivalentes no espaciales y estacionales, se destaca que la inclusión de un componente espacial en los modelos mejora significativamente la precisión de los pronósticos.	El rendimiento general de SpVAR fue un 30 % mejor que el de las redes neuronales artificiales espaciales (SpANN).
Katrís C. [54]	Pronóstico de la tasa de desempleo en varios países de diferentes regiones: Mediterráneo, Báltico, Balcanes,	Datos mensuales sobre tasas de desempleo ajustadas estacionalmente para 22 países de las regiones mencionadas anteriormente. El período cubierto fue de enero de 2000 a diciembre de 2014, considerando predicciones de un paso, tres pasos y doce pasos hacia adelante para los siguientes 12	<ul style="list-style-type: none"> - Promedio móvil integrado autorregresivo fraccional (FARIMA). - FARIMA con heterocedasticidad condicional autorregresiva generalizada (FARIMA/GARCH). - Red neuronal artificial (ANN). 	Los modelos se configuraron de la siguiente manera: a) en el modelo ARMA y FARIMA, se determinó primero el orden del modelo (p, q) utilizando el criterio de información Bayesiano (BIC) para seleccionar la mejor combinación, luego se	Los modelos FARIMA se encontraron claramente como la opción preferible para pronósticos de 1 paso adelante, mientras que, para períodos más largos (h = 12), los enfoques de redes neuronales lograron

	Nórdicos y Benelux.	meses hasta diciembre de 2017.	<ul style="list-style-type: none"> - Máquinas de vectores de soporte (SVM). - Splines de regresión adaptativa multivariada (MARS). 	<p>estimaron los parámetros del modelo FARIMA.</p> <p>b) en el modelo FARIMA/GARCH, se siguió un procedimiento similar al modelo FARIMA, pero se consideró el ajuste del modelo y un modelo GARCH(1,1) para para capturar la varianza condicional de los errores.</p> <p>c) en el modelo de Red Neuronal Artificial (ANN), se determinaron la tasa de remuestreo ($k=1$), el número de variables de entrada (1-4 variables rezagadas), el número de nodos en la capa oculta (1-10 nodos), las épocas de entrenamiento (500 periodos) y la función de activación sigmoid.</p> <p>d) en el modelo de Regresión de Vectores de Soporte (SVM), se utilizó una representación de alta dimensión del espacio de entrada y se seleccionó el modelo con el menor RMSE y</p> <p>e) en el modelo de Splines de Regresión Adaptativa Multivariable (MARS), se utilizó un procedimiento de partición recursiva para construir el modelo utilizando dos etapas: el paso hacia adelante y hacia atrás.</p>	<p>resultados comparables con los modelos basados en FARIMA.</p> <p>Para un horizonte de pronóstico de 3 pasos ($h = 3$), el modelo Holt-Winters resultó más adecuado.</p>
Ramli N. et al. [152]	Pronóstico de la tasa de desempleo de Malasia.	Tasa de desempleo de Malasia desde 1982 hasta 2013.	Fuzzy time series (FTS).	Se propone el uso de FTS con un enfoque de particionamiento natural considerando introducir un modelo de series temporales difusas utilizando datos en forma de números difusos trapezoidales y un enfoque de longitud de particionamiento natural, utilizar dos tipos de relaciones difusas: de primer y segundo orden, y que el modelo propuesto puede producir valores pronosticados bajo diferentes grados de confianza.	El tipo de relación difusa afecta el desempeño del pronóstico y el método propuesto puede proporcionar varios intervalos de pronóstico con diferentes grados de confianza.
Olmedo E. [153]	Pronóstico de la tasa de desempleo española.	Tasas de desempleo mensuales desestacionalizadas proporcionadas por EUROSTAT para 11 países europeos, incluida España,	<ul style="list-style-type: none"> - Baricéntrico. - VAR. - Regresión lineal. - Redes neuronales. 	En la configuración experimental se ajusta la función de reconstrucción y la red neuronal propuestas, calculando el error cuadrático medio	El predictor de regresión lineal puede mejorar las técnicas lineales de previsión en determinados

		que cubren el período comprendido entre enero de 1987 y octubre de 2011.		normalizado (NMSE) para dimensiones de incrustación de dos a diez y para un número diferente de vecinos (de 1 a 150) en el primer caso, y para 2 a 10 nodos en el segundo. Se seleccionan los parámetros en la fase de entrenamiento para cada país individualmente.	países, especialmente en la previsión a largo plazo. Los resultados proporcionados por el modelo VAR y el predictor baricéntrico empeoran a medida que aumenta el horizonte temporal. La regresión lineal y las redes neuronales muestran mejores resultados, especialmente en pronósticos a largo plazo.
Chakraborty . T. et al. [76]	Pronóstico de la tasa de desempleo en varios países: Canadá, Alemania, Japón, Países Bajos, Nueva Zelanda, Suecia y Suiza.	Datos mensuales y trimestrales de tasas de desempleo ajustadas estacionalmente para los países mencionados, obtenidos de repositorios de datos de acceso abierto: Datos económicos de la Reserva Federal (FRED) y Organización para la Cooperación y el Desarrollo Económicos (OECD).	<ul style="list-style-type: none"> - Promedio móvil integrado autorregresivo (ARIMA). - Redes neuronales artificiales (ANNs). - Red neuronal autorregresiva (ARNN). - Máquinas de vectores de soporte (SVM). - ARIMA con máquina de vectores de soporte (ARIMA-SVM). - ARIMA con red neuronal artificial (ARIMA-ANN). - ARIMA con red neuronal autorregresiva (ARIMA-ARNN). 	Se ajusta el modelo ARIMA a los datos y luego se entrena el modelo ARNN sobre los residuos de ARIMA para capturar las no linealidades residuales para cada país. Luego, los resultados del pronóstico de ARIMA junto con los pronósticos residuales de ARNN se suman para obtener los valores de pronóstico finales. Se comparan los resultados con otros modelos, y se utilizan las métricas de rendimiento como RMSE, MAE y MAPE para evaluar la precisión de las predicciones.	El modelo híbrido ARIMA-ARNN resulta en una mejor precisión de pronóstico en comparación con otros modelos individuales y híbridos.
Deng W. et al. [154]	Pronóstico de la tasa de desempleo USA.	Tasa de desempleo civil mensual desde el 1 de enero de 1948 hasta el 1 de diciembre de 2013.	Modelo combinado de múltiples granularidades basado en pronósticos de tendencias difusas, clustering automático y técnicas de PSO.	En la configuración experimental se realizan tres experimentos utilizando diferentes conjuntos de datos y métodos de comparación. Se utilizan algoritmos de clustering automático para generar diferentes longitudes de intervalos, y luego se aplican técnicas de series temporales difusas y teoría de cómputo granular para pronosticar tendencias difusas.	Los resultados indican que el modelo propuesto ofrece una mejora significativa en la precisión del pronóstico de la tasa de desempleo civil en USA.
Mohammed F. and Mousa M. [155]	Pronóstico de la tasa de desempleo USA.	Conjunto de datos bivariado de series temporales que incluye la tasa de desempleo y el tipo de cambio en los EE.UU. Los datos mensuales abarcan desde enero de 2000 hasta diciembre de 2017 para el	<ul style="list-style-type: none"> - Media móvil autorregresiva lineal estocástica (ARMAX). - Media móvil autorregresiva lineal estocástica con variable exógena con GARCH (ARMAX-GARCH). 	En la configuración experimental se aplican modelos GARCH y GARCHX para capturar la heterocedasticidad y no linealidad en la varianza condicional de ARMAX. Se seleccionan los modelos GARCH y GARCHX	El modelo híbrido ARMAX-GARCHX es más eficaz que otros modelos rivales individuales e híbridos gemelos para los datos en estudio.

		conjunto de entrenamiento y las últimas doce observaciones de enero a diciembre del 2018 se utilizan como conjunto de prueba para obtener el pronóstico fuera de muestra y para la validación.	- Media móvil autorregresiva lineal estocástica con variable exógena con GARCHX (ARMAX-GARCHX).	adecuados basados en criterios de AIC, BIC y HQ mínimos. Los modelos híbridos ARMAX-GARCH y ARMAX-GARCHX se comparan con modelos individuales y se evalúan mediante medidas de error como MAE, MAPE y RMSE.	
Shi L. et al. [55]	Pronóstico de la tasa de desempleo en países seleccionados de Asia.	Datos de desempleo de siete países en desarrollo de Asia: Irán, Sri Lanka, Bangladesh, Pakistán, Indonesia, China e India; los cuales provienen de la base de datos de índices financieros FRED.	- ARIMA con red neuronal autorregresiva (ARIMA-ARNN). - Media móvil integrada autorregresiva (ARIMA). - Redes neuronales artificiales (ANN). - Máquina de vectores de soporte (SVM). - ARIMA con red neuronal artificial (ARIMA-ANN). - ARIMA con máquina de vectores de soporte (ARIMA-SVM).	En la configuración experimental, se ajusta el modelo ARIMA para cada país seleccionado utilizando criterios como AIC y log-likelihood para seleccionar el mejor modelo. Posteriormente, se modelan los residuos de ARIMA utilizando ARNN, lo que permite capturar las no linealidades residuales presentes en los datos. Se emplea el paquete "predict" del entorno R-Studio para ajustar el modelo ARIMA y se utilizan técnicas de análisis gráfico, como los gráficos de autocorrelación (ACF) y autocorrelación parcial (PACF), para determinar los parámetros óptimos del modelo ARIMA. Una vez seleccionado el mejor modelo ARIMA para cada país, se procede a combinar los resultados de los modelos ARIMA y ARNN para generar pronósticos precisos de la tasa de desempleo. Además, se utilizan métricas de rendimiento como MAE, MAPE y RMSE para evaluar la calidad de los modelos.	El modelo híbrido ARIMA-ARNN mostró un mejor rendimiento en comparación con los competidores para las economías en desarrollo de Asia.
Yurtsever M. [78]	Pronóstico de la tasa de desempleo en Estados Unidos, Reino Unido, Francia e Italia.	Conjunto de datos de la tasa de desempleo mensual desde enero de 1983 hasta mayo de 2022 para los 4 países mencionados, obtenidos del sitio web de la OCDE.	LSTM-GRU.	Se normalizaron los datos entre 0 y 1 utilizando el escalador min-max. La arquitectura del modelo consta de una capa LSTM con 128 neuronas ocultas, una capa GRU con 64 neuronas ocultas y una capa densa con una neurona de salida.	LSTM-GRU mostró un mejor rendimiento en la predicción de la tasa de desempleo para los Estados Unidos, el Reino Unido y Francia, con excepción de Italia, donde el modelo GRU solo obtuvo mejores resultados.
Ahmad. M. et al. [77]	Pronóstico de la tasa de desempleo en países seleccionados	Se utilizaron datos de la tasa de desempleo mensual obtenidos del conjunto de datos económicos de FRED, disponibles en línea.	ARIMA. ANN. SVM. ARIMA-ARNN. ARIMA-ANN. ARIMA-SVM.	Los datos se dividieron en conjuntos de entrenamiento y prueba, y se aplicaron varios modelos y enfoques híbridos para pronosticar	El modelo híbrido ARIMA-ARNN mostró un buen rendimiento para Francia, Bélgica, Turquía y Alemania,

	<p>os de Europa: Francia, España, Bélgica, Turquía, Italia y Alemania.</p>		<p>la tasa de desempleo en los seis países. Se utilizaron criterios como el AIC (Criterio de Información de Akaike) para seleccionar los mejores modelos ARIMA para cada país. Los modelos híbridos combinaron las predicciones lineales de ARIMA con las predicciones no lineales de los modelos de redes neuronales o SVM. Se compararon los resultados de todos los modelos utilizando métricas de desempeño como RMSE, MAE y MAPE.</p>	<p>mientras que el modelo híbrido ARIMA-SVM fue sobresaliente para España e Italia. Estos resultados indican que la elección del mejor modelo puede variar según el país y las características específicas de los datos de desempleo.</p>
--	--	--	--	---

Apéndice C. Estudios para la predicción del IPC

Autores	Problema abordado	Conjunto de datos	Modelo propuesto	Configuración experimental	Resultados obtenidos
Eklund, J. & Kim J. M. [56]	Pronóstico del índice de precios al consumidor con el índice de sentimiento o del Comité Federal de Mercado Abierto (FOMC).	<p>Conjunto de datos llamado sentimientos que contiene 49 observaciones de siete de las siguientes variables: negativo, positivo, sentimiento, índice de sentimiento, archivo, año y mes.</p> <p>Asimismo, se utilizaron datos del IPC, NFCI y ANFCI.</p> <p>IPC: Los datos del IPC fueron obtenidos de la Oficina de Estadísticas Laborales de EE. UU. (https://www.bls.gov), específicamente los valores del IPC-U promedio de las ciudades de EE. UU. hasta noviembre de 2022, la data resultó en 71 observaciones de cuatro variables: IPC, mes, año, mesNum.</p> <p>NFCI y ANFCI: Los datos del NFCI y ANFCI se obtuvieron del Banco de la Reserva Federal de Chicago (https://www.chicagofed.org), que abarcan valores semanales desde enero de 1971 hasta diciembre de 2022, totalizando 2711 observaciones de ocho variables, de las cuales el estudio se centró en tres variables: viernes de semana, NFCI y ANFCI.</p>	<ul style="list-style-type: none"> - Regresión lineal. - Regresión de cópula de vid. - Regresión de cópula gaussiana (GCMR) con matriz de correlación ARMA(1,0). 	<p>La configuración experimental del modelo Gaussian Copula Regression (GCMR) con matriz de correlación ARMA(1,0) para predecir el Índice del Precio al Consumidor (IPC) utilizó una distribución normal multivariada y una matriz ARMA(1,0) seleccionada por tener el menor Akaike Information Criterion (AIC). Se emplearon 49 observaciones del índice de sentimiento FOMC, con una ventana de entrenamiento de las observaciones 30 a 48 y una ventana de prueba de las observaciones 31 a 49.</p>	<p>El mejor desempeño para pronosticar el IPC, en términos de raíz del error cuadrático medio (RMSE), error absoluto medio (MAE) y error porcentual absoluto medio (MAPE), se logró utilizando el modelo de regresión de cópula gaussiana (GCMR) con una matriz de correlación ARMA(1,0).</p>
Zeng X. Y. et al. [57]	Pronóstico de series difusas triangulares basados en modelo gris y red neuronal.	<p>La Oficina Estatal de Estadísticas de China ha proporcionado los registros del Índice de Precios al Consumidor (IPC) de cada mes. Para el análisis, se utiliza el valor medio, máximo y mínimo de los registros de doce meses de un año como el límite medio, izquierdo y derecho del número difuso triangular, respectivamente. Se toman los registros de los años 1997 a 2010 como la serie de datos para establecer los modelos</p>	<ul style="list-style-type: none"> - Modelo gris de números difusos triangulares (TFGM (1, 1)). - Red neuronal TFGM (1, 1) (NNTFGM (1, 1)). 	<p>Para predecir el Índice de Precios al Consumidor (IPC) utilizando el modelo NNTFGM (1, 1), se transforma la serie de datos del IPC en números difusos triangulares, que se dividen en series de centro de gravedad y longitud de intervalo para mantener el orden de los límites. A partir de esta serie transformada, se construye el modelo TFGM (1, 1), obteniendo predicciones iniciales para el IPC. Las series originales</p>	<p>La predicción de los índices de precios al consumidor y la carga energética del distrito Guilin de China ilustra que, para la serie fluctuante de números difusos (TF), la precisión de NNTFGM (1, 1) es mayor que la de TFGM (1, 1).</p>

		TFGM (1, 1) y NNTFGM (1, 1). Los valores para los años 2011 y 2012 serán predichos utilizando estos modelos.		y predichas se transforman y se calculan los residuos. Para mejorar la precisión de las predicciones, se utiliza una red neuronal de retropropagación (BP) que modela estas series de residuos, esta red se entrena con datos de residuos pasados para predecir los futuros. Luego, las predicciones iniciales del modelo TFGM (1, 1) se ajustan utilizando las predicciones de la red neuronal sobre los residuos. Este enfoque combinado proporciona predicciones más precisas del IPC para los años 2011 y 2012.	
Wang J. et al. [58]	Previsión del índice de precios al consumidor de China mediante un algoritmo inteligente integrado ARIMA-BP.	El dataset utilizado en el documento es el Índice de Precios al Consumidor (IPC) mensual de China desde marzo de 2011 hasta febrero de 2016.	- ARIMA-BP (propuesta). - ARIMA.	La configuración experimental del algoritmo integrado ARIMA-BP para la previsión del índice de precios al consumidor (IPC) de China se realizó en varios pasos. Primero, se estableció el modelo ARIMA transformando la serie temporal original del IPC en una serie estacionaria y realizando la prueba de raíz unitaria de Dickey-Fuller aumentada (ADF) para confirmar la estacionaridad de la serie transformada. Se determinó que el modelo ARIMA(2, 1, 2) era el más adecuado utilizando los criterios de información de Akaike (AIC) y Schwarz (SC) para minimizar los valores. Este modelo se utilizó para ajustar los datos mensuales del IPC desde marzo de 2011 hasta febrero de 2016 y obtener los valores previstos para marzo de 2016. Luego, se identificaron los errores de previsión del modelo ARIMA y se utilizaron como entrada para una red neuronal de retropropagación (BP). La red neuronal BP se entrenó utilizando Matlab	El algoritmo propuesto mostró un error de previsión que era menor que el del modelo ARIMA único.

				<p>para simular la parte no lineal de la variación del IPC. Para las predicciones subsecuentes, los datos reales del IPC desde octubre de 2015 hasta febrero de 2016 se utilizaron como entradas para la red neuronal BP, con el fin de obtener la previsión del IPC para marzo de 2016.</p> <p>Posteriormente, los datos reales del IPC desde noviembre de 2015 hasta febrero de 2016, junto con el valor previsto para marzo de 2016, se utilizaron para predecir el IPC de abril de 2016. Este proceso iterativo continuó, utilizando los datos reales más recientes y los valores previstos para generar las previsiones del IPC desde marzo de 2016 hasta julio de 2016.</p> <p>Finalmente, se combinaron las leyes lineales ajustadas por el modelo ARIMA y las no lineales simuladas por la red neuronal BP para generar los resultados de previsión del algoritmo integrado ARIMA-BP. La precisión del algoritmo integrado se evaluó comparando los resultados de previsión con los datos reales del IPC, demostrando una mayor exactitud en la previsión del IPC de China.</p>	
Powell B. et al. [81]	Mejorar la previsión del IPC utilizando datos de precios de alta frecuencia obtenidos mediante scraping web.	Se utilizaron dos conjuntos de datos principales: 1. Datos de precios extraídos de la web: Precios diarios extraídos de la web que cubren 33 categorías de productos extraídos de los sitios web de tres grandes supermercados que operan en el Reino Unido durante un período de	<ul style="list-style-type: none"> - Modelo informado (por datos web). - Modelo no informado (sin datos web). - Modelo persistente. 	Se desarrolló un modelo de proceso autorregresivo de primer orden AR(1) adaptado del modelo de "brecha de inflación p fija" de Faust y Wright para describir la evolución conjunta de las tasas de inflación diarias latentes que impulsan los precios observados en línea y los registrados en encuestas oficiales. Para la	En promedio, se puede ver que las estadísticas RMSE se reducen de 0.029 a 0.028 y a 0.025, a medida que se introduce la estructura del modelo y luego los datos extraídos de la web.

		aproximadamente 14 meses. 2. Datos del IPC desagregado: Valores de IPC desagregados para las mismas categorías de productos, así como muchos más que también contribuyen al IPC agregado, registrados y publicados por la Oficina Nacional de Estadísticas (ONS) mensualmente.		inferencia, se emplearon técnicas como el filtro de Kalman para ajustar secuencialmente las estimaciones de los parámetros latentes a medida que se recibían más datos, y se utilizó el ajuste bayesiano empírico para estimar los hiperparámetros del modelo. Este enfoque permitió manejar la alta frecuencia y la naturaleza desordenada de los datos obtenidos mediante web scraping, logrando predicciones precisas y ajustadas del Índice de Precios al Consumidor (IPC).	
Nguyen T. T. et al. [156]	Predicción del IPC de los Estados Unidos.	Los datos de enero de 2017 a febrero de 2022 se seleccionaron aleatoriamente y se dividieron en dos etapas: 80 % para entrenamiento y 20 % para prueba. Estos datos incluían variables como el CPI, el precio de compra inicial del petróleo crudo (OP), el precio mundial del oro (GP) y la tasa efectiva de los fondos federales (FFER).	<ul style="list-style-type: none"> - Regresión lineal multivariante (MLR). - Regresión de vectores de soporte (SVR). - Rezago distribuido autorregresivo (ARDL). - Splines de regresión adaptativa multivariante (MARS). 	Para examinar el IPC de EE. UU., se propuso un algoritmo que utiliza los modelos MLR, ARDL, MARS y SVR. Primero, la base de datos se preprocesó y se verificó su estacionariedad mediante pruebas de raíz unitaria (ADF y PP). Luego, los datos se dividieron en un 80% para entrenamiento y un 20% para prueba. Se aplicaron los modelos MLR, ARDL, MARS y SVR a los datos de entrenamiento para obtener los indicadores más precisos. El desempeño de estos modelos se evaluó usando métricas como MAPE, MAE, R ² y RMSE. MARS es un método adaptable y preciso que sigue un proceso detallado que incluye la selección de características más relevantes, la división del espacio de datos en varios subrangos basados en los valores de las características seleccionadas, el ajuste de funciones spline en cada subrango para capturar relaciones no lineales dentro de esos subrangos y la combinación de las funciones spline ajustadas para formar el modelo final de predicción del CPI.	Los modelos MLR, SVR, ARDL y MARS alcanzaron parámetros de alta precisión, mientras que el algoritmo MARS generó una mayor precisión en los pronósticos del IPC de Estados Unidos que los otros en la fase de prueba.
Sarang P. K. et al. [79]	Diseñar e implement	Para el diseño del modelo se han tomado datos	<ul style="list-style-type: none"> - ANN - ANN-PSO 	La configuración experimental del modelo	Al hibridar ANN con PSO, el error de

	<p>ar modelos de aprendizaje automático basados en redes neuronales optimizados con PSO y comparar los resultados con modelos ANN simples para predecir el IPC de la India.</p>	<p>secundarios (datos del IPC mensual para el periodo enero 2013 a mayo 2021 con año base 2012) del Ministerio de Estadística e Implementación de Programas (MSPI).</p>		<p>ANN-PSO se divide en dos fases. En la primera fase, se implementa una simple red neuronal artificial (ANN). La red se entrena con un conjunto de datos de entrenamiento y luego se prueba con patrones de prueba para calcular el error. La arquitectura y los parámetros de la red neuronal se ajustan mediante ensayos y errores para identificar la configuración óptima que minimiza el error. En la segunda fase, se introduce el algoritmo PSO para optimizar el modelo ANN. PSO es un método computacional basado en el comportamiento de enjambre de aves, que mejora los resultados de ANN al ajustar los pesos de la red neuronal de manera más efectiva que los métodos tradicionales de optimización. La implementación de PSO se inicia generando una población de posibles soluciones, las cuales se actualizan iterativamente para encontrar la mejor solución global. La configuración experimental se verifica mediante la validación cruzada y se evalúa la precisión del modelo utilizando MAPE.</p>	<p>pronóstico disminuye significativamente, lo que indica la alta precisión de los modelos.</p> <p>Los resultados experimentales muestran que la implementación de ANN-PSO proporciona una precisión muy alta en la mayoría de los conjuntos de datos probados, con valores de MAPE inferiores al 10%.</p>
<p>Álvarez-Díaz M. & Gupta R. [80]</p>	<p>Predecir, tanto en la muestra como fuera de ella, el índice de precios al consumidor (IPC) de la economía estadounidense</p>	<p>La base de datos está compuesta por datos mensuales del IPC de los EE. UU., tomados de la Base de Datos Financiera Global. La muestra cubre un período que va desde enero de 1980 hasta diciembre de 2013, con un total de 408 observaciones.</p>	<p>- Modelos univariados lineales: random walk (RW), autorregresivos (AR) y de promedio móvil integrado autorregresivo estacional (SARIMA)) - Modelos no lineales: redes neuronales artificiales (ANN) y programación genética (GP).</p>	<p>En el estudio se evaluaron varios modelos para predecir el índice de precios al consumidor (CPI) de EE. UU. utilizando datos mensuales del período 1980-2013. Se compararon modelos lineales univariados, como el random walk (RW), modelos autorregresivos (AR), y modelos de promedio móvil integrado autorregresivo estacional (SARIMA), con modelos no lineales, como las redes neuronales artificiales (ANN) y la programación genética (GP). Los datos se dividieron en tres submuestras: un período de entrenamiento/evolución</p>	<p>Los resultados mostraron que, aunque el modelo SARIMA tendía a producir los menores errores de pronóstico, no hubo diferencias estadísticas significativas en comparación con los modelos no lineales y AR de orden superior. Sin embargo, los modelos simples RW y AR(1) fueron estadísticamente superados por SARIMA, ANN y GP, lo que sugiere que los modelos lineales bien especificados y</p>

				<p>(enero 1980 – diciembre 2003), un período de selección (enero 2004 - julio 2010) y un período fuera de muestra (agosto 2010 -diciembre 2013). Esta división permitió entrenar y validar los modelos en los primeros dos subperíodos y evaluar la precisión de sus predicciones en el último. La implementación de los modelos ANN y GP implicó un proceso de prueba y error para seleccionar la arquitectura óptima de la red y la mejor ecuación evolutiva, respectivamente. En el caso de ANN, se utilizó una red neuronal autoregresiva no lineal (NAR) con diferentes configuraciones de lags y funciones de activación. Para GP, se generaron y evaluaron más de 120,000 ecuaciones matemáticas para encontrar la que mejor representara la dinámica del CPI. El modelo SARIMA se construyó probando diferentes órdenes estacionales y no estacionales, seleccionando finalmente el modelo que minimizaba el criterio de información bayesiano (BIC). La evaluación del rendimiento predictivo se basó en el error porcentual absoluto medio (MAPE) y en el test de Diebold-Mariano (DM) para comparar la precisión de los modelos.</p>	<p>los no lineales avanzados son más adecuados para predecir el CPI.</p>
--	--	--	--	---	--

Apéndice D. Estudios para la predicción de la tasa de cambio

Autores	Problema abordado	Conjunto de datos	Modelo propuesto	Configuración experimental	Resultados obtenidos
Lu C. et al. [59]	Mejorar la precisión en la predicción del tipo de cambio del Renminbi (RMB) y en la medición del riesgo mediante la combinación de modelos de aprendizaje profundo con modelos tradicionales como ARMA-GARCH	Todos los datos experimentales provienen del conjunto de datos públicos (https://www.quandl.com/). Se utilizaron datos históricos de siete mercados principales de tipo de cambio, incluyendo RMB, Euro, Yen Japonés, Dólar Canadiense, Dólar Australiano, Libra Esterlina y Franco Suizo. Los datos abarcan desde octubre de 2008 hasta octubre de 2019, con un total de 2,595 observaciones para cada mercado.	Para la predicción del tipo de cambio se propone el modelo que integra la red de creencias profundas (DBN) y el modelo de memoria a largo y corto plazo (LSTM) en redes neuronales recurrentes. Para la medición de riesgo VaR se propone el modelo integrado basado en aprendizaje profundo que combina la descomposición empírica en modos (EMD) con el modelo de media móvil autorregresiva/modelo de heterocedasticidad condicional autorregresiva generalizada (ARMA-GARCH)	La configuración experimental incluye la división de los datos en un conjunto de entrenamiento (70%) y un conjunto de prueba (30%). El modelo DBN tiene 2 capas ocultas con 100 nodos de entrada y utiliza una función de activación de corrección lineal. La tasa de aprendizaje en el modelo se establece en 0.01 y los valores de los parámetros relevantes, como los pesos, se obtienen a través de 2000 ciclos de entrenamiento, a fin de obtener la estructura de red del modelo DBN. El modelo LSTM tiene 1 capa de entrada con 2 nodos, 2 capas ocultas, cada una con 4 nodos y 1 capa de salida con 1 nodo.	El modelo DBN+LSTM propuesto mostró un rendimiento superior en la predicción del tipo de cambio en comparación con los modelos tradicionales como ARMA y GARCH, con una precisión máxima del 74.92%. Además, el modelo de medición de riesgo VaR integrado mostró alta fiabilidad y precisión, superando a los modelos de medición de riesgo tradicionales.
Luo T. et al. [60]	Mejorar la precisión en la predicción de la volatilidad del tipo de cambio USD/CNY.	Datos diarios del tipo de cambio USD/CNY (CUR) desde el 1 de enero de 2010 hasta el 31 de marzo de 2023. Además, se consideran nueve índices de incertidumbre diferentes, incluidos el índice de búsqueda de Google (GSI), condiciones económicas globales (GEC), índice de volatilidad de ETF de oro (GVZ), índice de riesgo geopolítico (GPR), índice de incertidumbre de política económica global (GEP), índice de incertidumbre de política económica china (CNEPU), índice de incertidumbre de política económica estadounidense (USEPU), índice de incertidumbre de política comercial de China (CNTPU) e índice de incertidumbre de política comercial estadounidense (USTPU).	Se extiende el modelo GARCH-MIDAS con los 9 índices de incertidumbre seleccionados.	El modelo se evaluó tanto dentro como fuera de muestras. Para la evaluación fuera de muestra, se utilizaron pruebas como el conjunto de confianza del modelo (MCS) y la prueba de dirección de cambio para medir la capacidad predictiva del modelo y su capacidad para predecir la dirección de los cambios en la volatilidad del tipo de cambio USD/CNY. Se probaron varias configuraciones del modelo GARCH-MIDAS, incorporando diferentes combinaciones de los nueve índices de incertidumbre. Además, se aplicaron múltiples funciones de pérdida para medir el error de predicción, y se realizaron pruebas de robustez utilizando diferentes ventanas temporales. Finalmente, se evaluó el impacto de eventos geopolíticos, como el conflicto entre Rusia y	El modelo extendido GARCH-MIDAS mostró una buena capacidad predictiva para la volatilidad del tipo de cambio USD/CNY, especialmente cuando se incorporaron ciertos índices de incertidumbre. En particular, el índice de incertidumbre de la política comercial de EE.UU. (USTPU) fue el que tuvo el mayor impacto en la mejora de la capacidad predictiva del modelo. Además, la evaluación fuera de muestra reveló que el modelo GARCH-MIDAS-USTPU alcanzó la mayor precisión predictiva en comparación con otros modelos. Este modelo también demostró ser especialmente útil

				Ucrania, en la capacidad predictiva del modelo.	para predecir la volatilidad a largo plazo del tipo de cambio USD/CNY.
Wang J. et al. [61]	Predicción del precio de cierre del tipo de cambio USD/CNY para el próximo día de negociación.	Datos de las transacciones diarias del tipo de cambio USD/CNY, junto con datos de índices bursátiles como el Nasdaq, el promedio industrial Dow-Jones, el índice compuesto de Shanghái y el índice Hang Seng desde el 2 de enero de 2006 hasta el 30 de octubre de 2020.	<ul style="list-style-type: none"> - El Modelo híbrido propuesto es CNN-TLSTM. - Perceptrón multicapa (MLP). - Red neuronal convolucional (CNN). - Red neuronal recurrente (RNN). - Memoria a largo y corto plazo (LSTM). - CNN-LSTM. 	El Modelo híbrido CNN-TLSTM combina redes neuronales convolucionales (CNN) para la extracción de características y una variación del modelo LSTM llamada TLSTM para manejar la predicción de series temporales. El modelo procesa y predice el precio de cierre del USD/CNY. Se utilizaron datos de entrenamiento desde el 2 de enero de 2006 hasta el 31 de diciembre de 2019, y los datos de prueba fueron desde el 1 de enero de 2020 hasta el 30 de octubre de 2020. Se compararon los resultados del modelo CNN-TLSTM con otros modelos como MLP, CNN, RNN, LSTM y CNN-LSTM utilizando métricas de error absoluto medio porcentual (MAPE), error cuadrático medio (MSE) y R-cuadrado (R^2).	El modelo CNN-TLSTM tuvo la mejor capacidad predictiva en comparación con los otros modelos probados. Específicamente, el CNN-TLSTM logró el menor MAPE y MSE, y el mayor R^2 , lo que indica una alta precisión en la predicción del precio de cierre del tipo de cambio USD/CNY para el próximo día de negociación.
Neghab D. et al. [157]	Predicción de la tasa de cambio del dólar canadiense a dólar estadounidense	El conjunto de datos utilizado incluye variables macroeconómicas y la tasa CAD/USD como variable objetivo, cubriendo el período de enero de 2009 a diciembre de 2021. Las variables macroeconómicas incluyen el precio del petróleo Intermedio del Oeste de Texas (WTI), el precio del oro, índices bursátiles (TSX y S&P 500), la tasa interbancaria LIBOR, la paridad de la tasa de interés a corto plazo, la paridad de los índices de precios al productor, la oferta monetaria, la tasa de desempleo y el índice de producción industrial. Los valores promedio diarios del tipo de cambio CAD/USD se obtuvieron del Banco de Canadá y para recopilar 10 variables macroeconómicas se usaron 3 bases de datos: Cooperación y el Desarrollo Económicos	<ul style="list-style-type: none"> - Máquina ligera potenciadora de gradiente (LGBM) - Regresor de árboles adicionales (ETR) - Aumento Extremo del Gradiente (XGB) - Regresión de cresta (RIDGE) - Operador de selección y contracción mínima absoluta (LASSO) - Unidades Recurrentes Cerradas (GRU) - (Modelo Autorregresivo con rezago 1 (AR(1))) - Caminata aleatoria (RW) 	La configuración experimental incluyó la división del período de estudio en diferentes subperíodos (expansión económica, estancamiento económico y período de COVID) para evaluar el rendimiento del modelo en diferentes ciclos económicos. Se utilizó un enfoque de ventana deslizante de 2.5 años (30 meses), en el que los datos se dividen en conjuntos de entrenamiento y prueba (80:20) para entrenar y evaluar los modelos, avanzando iterativamente hasta cubrir todo el rango de datos de 2009 a 2021. Se emplearon métricas como el error cuadrático medio (RMSE), el error cuadrático medio normalizado (NRMSE), y la desviación absoluta media (MAE) para evaluar el rendimiento.	LASSO y LGBM son los mejores modelos para predicciones a corto plazo (1 día y 1 semana, respectivamente). LGBM también se destaca para predicciones de 5 días, mientras que RIDGE es mejor para 5 semanas. Para predicciones a más largo plazo (10 periodos), XGB supera a los demás. Estos resultados se basan en el rendimiento promedio a lo largo de 22 ventanas móviles durante el período entre 2009 y 2021.

		(OCDE), Yahoo Finance y el Banco de la Reserva Federal de St. Louis (FRBSL).			
Mattera R. et al. [158]	El artículo aborda el problema de la previsión de los tipos de cambio.	Se utilizaron datos trimestrales del tipo de cambio entre el dólar canadiense (CAD) y el dólar estadounidense (USD), recopilados de la base de datos FRED y se calculó el logaritmo del tipo de cambio nominal mensual CAD/USD desde el 01/01/1985 hasta el 01/01/2019. Asimismo, se consideraron los predictores clásicos de los tipos de cambio sugeridos por la teoría económica: diferenciales entre las tasas de interés de corto plazo nacionales y extranjeras, niveles de precios, PIB, producción y oferta monetaria.	<ul style="list-style-type: none"> - Paridad de tasas de interés a descubierto (UIRP). - Paridad del poder adquisitivo (PPP). - Modelos monetarios con precios flexibles (MM₁) y precios rígidos (MM₂). - Modelos basados en la regla de Taylor con ajustes instantáneos (TYLR₁) y suavizados (TYLR₂). - Frecuencia mixta de la paridad de tipos de interés descubierta (MF-UIRP). - Frecuencia mixta de la paridad del poder adquisitivo (MF-PPP). - Frecuencia mixta del modelo monetario de precios flexibles (MF-MM₁). - Frecuencia mixta del modelo monetario de precios rígidos (MF-MM₂). - Frecuencia mixta de la regla de Taylor instantánea (MF-TLYR₁). - Frecuencia mixta de la regla de Taylor con suavizado (MF-TLYR₂). 	Se utilizó un enfoque de predicción fuera de muestra, utilizando tanto un esquema de ventana deslizante como un esquema recursivo. Estos enfoques se emplean para comparar la precisión de los modelos clásicos y los modelos MIDAS propuestos. Para evaluar la precisión de las predicciones, se utilizan diferentes funciones de pérdida, como el Error Cuadrático Medio de la Predicción (MSFE), Error Absoluto Medio de la Predicción (MAFE) y Raíz del Error Cuadrático Medio de la Predicción (RMSFE).	Los resultados muestran que los modelos MIDAS propuestos mejoran la precisión de las predicciones en comparación con los modelos clásicos. En particular, el MF-UIRP es un 2,3% más preciso que el UIRP, el MF-PPP es un 8,2% más preciso que el PPP y el MF-TLYR ₂ es un 18% más preciso que el TLYR ₂ . El mayor beneficio de considerar un modelo de frecuencia mixta se alcanza, en términos de precisión, con la versión de precio fijo de frecuencia mixta del modelo monetario (MF-MM ₂), que es un 53,6% más precisa que el modelo MM ₂ clásico.
Abedin M. et al. [159]	Predicción de las tasas de cambio de 21 monedas frente al USD tanto en periodos previos como durante la pandemia.	El conjunto de datos proviene de Kaggle y Oanda. Incluye datos históricos de tasas de cambio de 21 monedas frente al USD, cubriendo periodos antes y durante la pandemia de COVID-19. Los datos se dividen en dos grupos: antes y durante la pandemia de COVID-19. A su vez, el grupo durante COVID-19 se dividió en siete subgrupos basados en casos (C1-C4) y eventos (E1-E3) confirmados de COVID-19.	<ul style="list-style-type: none"> - Árbol de Decisión (RT). - Regresión con Soporte Vectorial (SVR). - Bosques Aleatorios (RF). - Regresión Cresta (BR). - Memoria a largo y corto plazo (LSTM). - Bidireccional LSTM (Bi-LSTM). - Bidireccional LSTM con Ensamblado Ridge (Bi-LSTM BR) (propuesta). 	El modelo Bi-LSTM BR se entrena y evalúa en varios subconjuntos de datos que se dividen según las olas de casos de COVID-19 y las políticas gubernamentales en los Estados Unidos. Se aplican métricas como el error cuadrático medio (RMSE), el error absoluto medio (MAE), y el error porcentual absoluto medio (MAPE) para evaluar el rendimiento del modelo. Además, se utiliza validación cruzada de 10 veces para mejorar la generalización del modelo en el periodo previo al COVID-19, reduciendo el riesgo de sobreajuste y asegurando que el modelo sea robusto tanto en periodos de alta volatilidad	El estudio muestra que el modelo propuesto Bi-LSTM BR supera a los modelos comparados, proporcionando un rendimiento de predicción robusto tanto durante los periodos de COVID-19 como en los periodos previos. Los resultados también indican variaciones significativas en el rendimiento del modelo durante los periodos de alta volatilidad en los mercados de divisas durante la pandemia.

				como en periodos más estables.	
KartonoA. et al. [160]	Predicción de los tipos de cambio del dólar estadounidense (USD) a la rupia indonesia (IDR) utilizando las ecuaciones incompresibles de Navier-Stokes modificadas con parámetros económicos.	Se utilizaron datos reales de tasas de cambio del USD al IDR obtenidos de fuentes oficiales como el Banco de Indonesia cubriendo el periodo de febrero de 2018 a enero de 2019. Además, se incluyeron datos macroeconómicos como tasas de inflación, tasas de interés, balanza comercial y PIB de ambos países (USA e Indonesia).	El estudio propone un modelo basado en una versión modificada de las ecuaciones de Navier-Stokes, adaptadas con parámetros económicos, para modelar el comportamiento de las tasas de cambio.	El modelo se implementó utilizando datos semanales como entrada para predecir las tasas de cambio diarias a lo largo de un mes. Los datos económicos utilizados incluyen la tasa de inflación, tasa de interés, balanza comercial y PIB de ambos países. Finalmente, se compararon los resultados de las predicciones con los datos reales para evaluar la precisión del modelo.	Los resultados mostraron que el modelo basado en las ecuaciones de Navier-Stokes pudo predecir las tasas de cambio con un error medio de menos del 2.5% en comparación con los datos reales, indicando una alta precisión del modelo en la predicción de las tasas de cambio del USD al IDR.
Hua R. et al. [161]	Predicción de la tasa de cambio del RMB (Renminbi) frente al dólar estadounidense (USD) utilizando modelos avanzados.	Tipo de cambio, tasa de rendimiento de los bonos de China y tasa de interés de los bonos del Tesoro de Estados Unidos obtenidos desde el Banco de la Reserva Federal de St. Louis, el repositorio China-Bond.com y la Junta de la Reserva Federal de los Estados Unidos, respectivamente.	<ul style="list-style-type: none"> - Modelo Nelson-Siegel. - Modelo de red neuronal. - Modelo ARIMA. 	La red neuronal feedforward de dos capas ocultas fue diseñada para predecir la tasa de cambio del RMB frente al USD. Los factores de nivel, pendiente y curvatura, extraídos del modelo Nelson-Siegel aplicado a las curvas de rendimiento de los bonos de China y Estados Unidos, se utilizan como entradas para esta red neuronal. La red emplea una función de activación tan-Sigmoid en las capas ocultas y una función lineal en la capa de salida. Para determinar el número óptimo de neuronas en las capas ocultas, se utilizó un método empírico que resultó en la selección de 10 neuronas. El modelo fue entrenado utilizando el algoritmo de regularización bayesiana, que es adecuado para manejar series temporales con ruido, y se evaluaron los resultados para periodos de predicción de 1, 3, 6 y 12 meses. Durante el entrenamiento, los datos se dividieron en tres conjuntos: 70% para el entrenamiento, 15% para la prueba y 15% para la validación.	El modelo de red neuronal mejoró la precisión en la predicción de las fluctuaciones del tipo de cambio en comparación con otros modelos de referencia como el ARIMA y el Nelson-Siegel tradicional.
Xie W. et al. [65]	Predicción de la tasa	Se utilizaron más de 30,000 unidades de datos	- Red neuronal de retropropagación (BP).	El modelo EMD-LSTM-SVR maximiza la capacidad de	Los resultados empíricos

	<p>de cambio USD/CNY, que presenta características no estacionarias y no lineales, lo que puede causar sesgos significativos si se utilizan modelos tradicionales lineales o de máquina única.</p>	<p>sobre el precio de apertura del tipo de cambio USD/CNY desde el 2 de enero de 2015 hasta el 30 de abril de 2022.</p>	<ul style="list-style-type: none"> - Memoria a largo y corto plazo (LSTM). - Red neuronal recurrente (RNN). - Red neuronal de regresión general (GRNN). - Modelo que combina la descomposición modal empírica, las redes neuronales de memoria a largo y corto plazo y la regresión de soporte vectorial (EMD-LSTM-SVR) 	<p>generalización, mejora la capacidad de captura de características no lineales y previene de manera más efectiva el desvanecimiento del gradiente y el sobreajuste. Para la evaluación del modelo, se utilizó un conjunto de datos de más de 30,000 unidades de la tasa de cambio USD/CNY, distribuyendo el 80% de los datos para el entrenamiento y el 20% para las pruebas.</p> <p>El proceso de optimización del modelo comenzó con la EDM para descomponer la serie temporal en componentes más simples y manejables, reduciendo así la complejidad y la no linealidad inherente de los datos originales. Posteriormente, se utilizó una red neuronal LSTM para predecir las fluctuaciones dentro de cada componente descompuesto, aprovechando su capacidad para aprender dependencias a largo plazo en datos secuenciales. Finalmente, se aplicó un ajuste mediante SVR para corregir y minimizar los errores residuales, garantizando una predicción más precisa y estable.</p>	<p>mostraron que el modelo EMD-LSTM-SVR tuvo una alta precisión en la predicción de las fluctuaciones del tipo de cambio, y logró que la mayoría de las posiciones predichas se desviaran menos de las posiciones reales. Comparado con los modelos referenciales, redujo significativamente el error absoluto medio y mejoró la precisión general.</p>
<p>Pandey T. N. et al. [162]</p>	<p>Se aborda la predicción del tipo de cambio, que es crucial para la toma de decisiones financieras y de gestión. Las fluctuaciones en el tipo de cambio afectan la economía</p>	<p>Se utilizaron datos diarios de tasas de cambio entre varias monedas, incluyendo EUR/USD, GBP/USD, y USD/JPY. Los datos se recopilaron para diferentes periodos, como diario, mensual y trimestral; y provienen de varias fuentes como GlobalView, Onda Smarter Trading, DataStream, Reserva Federal de St. Louis y sitio web "Servicio de cambio de divisas del Pacífico" del profesor Werner Antweiler de la</p>	<ul style="list-style-type: none"> - Red neuronal (NN). - Paseo aleatorio (RW). - Heterocedasticidad condicional autorregresiva generalizada (GARCH). - Modelo de media móvil integrado autorregresivo (ARIMA). - Perceptrón multicapa (MLP) con aprendizaje de retropropagación. - MLP con aprendizaje bayesiano. - Función de base radial (RBF) multietapa. - RBF simple. 	<p>El modelo de máquina de comité se configura seleccionando varios modelos expertos, tanto redes neuronales como modelos estadísticos, que han demostrado buen rendimiento en la predicción de tasas de cambio. Cada uno de estos modelos se entrena por separado utilizando un conjunto de datos específico. Las salidas de estos modelos se combinan de manera no lineal mediante un sistema de compuertas, donde los</p>	<p>Los resultados muestran que el modelo máquina de comité supera en precisión a los enfoques individuales y otros modelos estándar, demostrando su eficacia en la predicción de tasas de cambio.</p>

	de un país, impactando tasas de interés, desempleo, precios y salarios; por lo tanto, su predicción con precisión es vital para el crecimiento económico de cualquier país.	Universidad de Columbia Británica.	<ul style="list-style-type: none"> - Promedio simple. - MSE simple. - Regresión de pila. - Método basado en varianza utilizada. - MLP simple. - RBF simple. - ARIMA simple. - Modelo híbrido (combinación de MLP, RBF y ARIMA). - Red neuronal artificial de enlace funcional (FLANN). - Red neuronal artificial de enlace funcional en cascada (CFLANN). - Máquina de comité. 	resultados individuales se ponderan utilizando un método probabilístico. Esto permite optimizar la precisión de la predicción al dar mayor peso a los modelos que ofrecen mejor rendimiento en un conjunto de validación. Finalmente, el rendimiento del modelo de máquina de comité se evalúa a través de métricas como el error cuadrático medio (RMSE) y el error cuadrático medio normalizado (NMSE), comparando los resultados obtenidos con los de los modelos individuales. Además, se realizan pruebas utilizando un conjunto de datos común para asegurar una comparación justa.	
Yağmur A. et al. [163]	Predicción de la tasa de cambio de dólar estadounidense a lira turca (USD/TL)	Tasas de cambio diarias entre USD y TRY desde el 1 de enero de 2001 hasta el 10 de agosto de 2020, excluidos los fines de semana y los días festivos, con un total de 4,930 puntos de datos. Estos datos fueron obtenidos del Banco Central de la República de Turquía.	<ul style="list-style-type: none"> - Memoria a largo y corto plazo (LSTM) (propuesta). - Modelo de media móvil integrado autorregresivo (ARIMA). - Perceptrón multicapa (MLP). 	El modelo LSTM está compuesto por una capa de entrada, seguida de dos capas LSTM apiladas, una capa lineal y una capa de salida con una única neurona. Las capas LSTM apiladas contienen 128 neuronas, y la última capa oculta es una MLP con 10 neuronas. Se utiliza el optimizador Adam con una tasa de aprendizaje de 0.001. La función de pérdida empleada es el error cuadrático medio (MSE), y en las capas LSTM se aplica la función de activación ReLU. El modelo se entrena durante 1000 épocas con un tamaño de lote de uno para realizar previsiones de un paso a la vez en el conjunto de prueba.	Los resultados del estudio muestran que las redes neuronales (NN) LSTM superan a los modelos ARIMA y MLP. En particular, el modelo LSTM obtuvo un error medio absoluto (MAE) de 0.018 y una raíz del error cuadrático medio (RMSE) de 0.037, lo cual indica una mejora significativa respecto a los otros modelos.
Hu C. et al. [164]	Predicción de la tasa de cambio del dólar estadounidense / rupia, que es crucial tanto para países como para empresas debido a su impacto en el comercio	El conjunto de datos utilizado en el experimento son los datos históricos del tipo de cambio del dólar estadounidense y la rupia, con 5 muestras de datos los 7 días de la semana. Al utilizar el modelo, el lapso de tiempo de los datos históricos no debe ser demasiado extenso; es preferible considerar un período de 6 a 10 años	<ul style="list-style-type: none"> - Red neuronal BP (retropropagación). - Modelo básico de LSTM. - Modelo optimizado de LSTM con una estructura jerárquica y un mecanismo de atención (propuesta). 	La configuración experimental del modelo optimizado LSTM se estructura en varias capas (capa de fecha, capa de año, capa intermedia y capa de salida) que trabajan de manera conjunta para mejorar la precisión en la predicción de la tasa de cambio. El modelo fue entrenado durante 50 épocas con un tamaño de lote de 72, utilizando la función de	El modelo optimizado de LSTM superó tanto al modelo BP como al modelo básico de LSTM en términos de precisión. El error de predicción del modelo optimizado fue significativamente menor (perdida de prueba=0.0055), demostrando su efectividad en la

	internacional y la estabilidad económica.	para obtener un error más razonable.		pérdida de error absoluto medio (MAE) para evaluar su rendimiento y el optimizador Adam para actualizar sus pesos. Se empleó la función de activación ReLU en las unidades LSTM para evitar problemas como la explosión o el desvanecimiento del gradiente.	predicción de tasas de cambio al considerar datos históricos de múltiples niveles temporales y aplicar un mecanismo de atención.
Kartono A. et al. [165]	El estudio se enfoca en la complejidad de predecir los movimientos de la tasa de cambio debido a la volatilidad y la influencia de varios factores macroeconómicos, específicamente el estudio se enfoca en la predicción de la tasa de cambio entre el dólar estadounidense (USD) y la rupia indonesia (IDR).	Datos de las variables económicas (tasa de inflación, tasa de interés, producto interno bruto (PIB) y tasas de retorno) que afectan el tipo de cambio (IDR/USD) durante 13 meses en el período de febrero de 2018 a febrero de 2019.	Modelo basado en las ecuaciones de Schrödinger no lineales (NLSE) para predecir la tasa de cambio.	El modelo NLSE propuesto utiliza una analogía entre los parámetros de las ecuaciones de Schrödinger y las variables macroeconómicas. El modelo se resuelve utilizando el método numérico de Runge-Kutta de cuarto orden para calcular la evolución de la función de onda que representa la tasa de cambio. Los parámetros macroeconómicos se incorporan en la ecuación para predecir la tasa de cambio mensual.	El modelo NLSE es efectivo para capturar y predecir la volatilidad en la tasa de cambio, mostrando un error de predicción mensual inferior al 2.5% en promedio. Los resultados de la predicción basados en el cálculo del valor del error porcentual absoluto medio (MAPE) son del 0.48%.
Jannová M. & Rousek P. [166]	Predicción del tipo de cambio entre el euro y la corona checa (EUR/CZK)	Se utilizó un conjunto de datos históricos de precios diarios del tipo de cambio EUR/CZK, abarcando el período de 2003 a 2023. Los datos fueron obtenidos del sitio web Yahoo.com y se usaron 5047 puntos de datos para el análisis.	- Perceptrón multicapa (MLP) (propuesta). - Función de base radial (RBF).	Para las redes MLP, se utilizaron entre 2 y 20 neuronas en la capa oculta. El algoritmo de entrenamiento utilizado fue Broyden-Fletcher-Goldfarb-Shanno (BFGS). Se construyeron 1000 redes neuronales, de las cuales se seleccionaron las 10 mejores para realizar las predicciones. Los datos se dividieron en tres conjuntos: 70% para entrenamiento, 15% para pruebas y 15% para validación.	Las redes MLP seleccionadas mostraron un alto coeficiente de correlación (superior a 0.979) en todos los conjuntos de datos (entrenamiento, prueba y validación), indicando un rendimiento robusto en la predicción del tipo de cambio EUR/CZK. A pesar de que las redes neuronales no lograron captar adecuadamente las

					fluctuaciones extremas, tanto en los mínimos como en los máximos locales, siguen siendo aplicables en la práctica.
Midilli Y. E. & Parsutins S. [167]	Identificación de los hiperparámetros óptimos en redes neuronales profundas para la predicción del tipo de cambio entre USD/CAD durante el año 2019.	Los datos del mercado contienen las siguientes características del tipo de cambio USD/CAD: sello de tiempo, precio de apertura, precio más alto, precio más bajo y precio de cierre (OHLC).	<ul style="list-style-type: none"> - Perceptrón multicapa (MLP). - Redes neuronales recurrentes (RNN). - Redes de memoria a larga a corto plazo (LSTM). 	Se utiliza un diseño experimental de Box-Behnken con los niveles de hiperparámetros establecidos para el tamaño de época, la tasa de aprendizaje, el tamaño de lote, el número de capas ocultas y el número de neuronas ocultas. El modelo se entrena, valida y prueba en 41 iteraciones para cada configuración, y se realiza un análisis de varianza (ANOVA) para identificar los factores que tienen un efecto significativo en el rendimiento.	El modelo MLP tiene el valor MAE más bajo (0.00162) y el modelo LSTM tiene la variación más baja a través de diferentes ensayos de prueba (0.00041).
Biswas A. et al. [168]	Mejorar la precisión de las predicciones entre el dólar estadounidense (USD) y el taka bangladés (BDT) mediante la inclusión de factores macroeconómicos que influyen en el tipo de cambio.	Se utilizaron datos históricos del tipo de cambio USD/BDT obtenidos del Banco Central de Bangladesh y 16 factores macroeconómicos tanto de Estados Unidos como de Bangladesh obtenidos de la página web "Trading Economics", desde el año 2000 hasta 2019. El conjunto de datos contiene un total de 5000 registros de tipos de cambio USD/BDT. Estos factores macroeconómicos son: <ul style="list-style-type: none"> - Para Estados Unidos: producto interno bruto (PIB), tasa de inflación, reservas extranjeras, exportaciones, importaciones, oferta monetaria (M0), oferta monetaria (M1) y tasa de interés. - Para Bangladesh: ingresos del gobierno, oferta monetaria (M0), oferta monetaria (M1), balanza comercial, exportaciones, importaciones, tasa de crecimiento anual del PIB y tasa de inflación. 	<ul style="list-style-type: none"> - LSTM. - Bi-LSTM. - Stacked-LSTM. - GRU. - ANN. - CNN. - CNN-LSTM. - Codificador-Decodificador. - MLP distribuido en el tiempo. - SVM. - XGBoost. 	El modelo "MLP distribuido en el tiempo" se configuró con cuatro capas, utilizando la función de activación ReLU, una tasa de aprendizaje de $2e-3$, y una tasa de abandono (dropout) de 0.1. Se optimizaron los hiperparámetros utilizando técnicas avanzadas de optimización como la búsqueda en cuadrícula, búsqueda aleatoria y optimización bayesiana. El modelo se entrenó utilizando 3500 registros, con un proceso de validación y ajuste de pérdidas aplicando las técnicas de puntos de control (checkpoints) y llamadas de parada anticipada (early stopping callbacks).	El modelo MLP distribuido en el tiempo logró el mejor resultado RMSE (0.1984) de entre los modelos probados. Dicha métrica se redujo a 0.1900 después de aplicar una canalización (pipeline) propuesta para el tipo de cambio USD/BDT.
Peng Q. et al. [169]	El estudio aborda la capacidad de	Se utilizaron datos de precios de cierre diarios del JYVIX y del tipo de cambio USD/JPY,	- Modelos GARCH: GARCH(1,1), GARCH(2,1), EGARCH, GJR-GARCH para	El modelo propuesto EGARCH con JYVIX usa los datos diarios del tipo de cambio USD/JPY y el índice	El modelo EGARCH combinado con JYVIX como variable exógena demostró

	predicción de la volatilidad implícita del índice de volatilidad del yen japonés (JYVIX) en relación con la volatilidad futura del tipo de cambio entre el dólar estadounidense y el yen japonés (USD/JPY).	obtenidos de los sitios web CBOE e Investing, actualizado por última vez el 29 de mayo de 2015. Se cubre el período del 2 de enero de 2007 al 29 de mayo de 2015, con un total de 2113 observaciones en total.	predecir la volatilidad condicional del tipo de cambio USD/JPY. - ARMA para la predicción del índice de volatilidad implícita del yen japonés (JYVIX). - Modelos GARCH combinados con JYVIX: Se probaron dos combinaciones principales para mejorar la predicción de la volatilidad: 1. JYVIX como variable independiente en una regresión junto con las predicciones de los modelos GARCH. 2. JYVIX como variable exógena directamente dentro de los modelos GARCH, resultando en las siguientes combinaciones: - GARCH(1,1) con JYVIX como variable exógena. - GARCH(2,1) con JYVIX como variable exógena. - GARCH(1,2) con JYVIX como variable exógena. - EGARCH con JYVIX como variable exógena. - GJR-GARCH con JYVIX como variable exógena.	de volatilidad implícita JYVIX. En este modelo, JYVIX se incorpora como una variable exógena en el modelo EGARCH, lo que permite capturar mejor la volatilidad condicional del tipo de cambio USD/JPY. Mediante esta combinación el modelo aprovecha la información histórica a través de EGARCH y la información prospectiva proporcionada por JYVIX.	tener la mayor capacidad predictiva para la volatilidad condicional del tipo de cambio USD/JPY frente a los modelos GARCH tradicionales.
Liu S. et al. [66]	Las tasas de cambio están sujetas a alta volatilidad e incertidumbre, por lo que se busca mejorar la precisión de las predicciones del tipo de cambio USD/CNY mediante el desarrollo de un enfoque de aprendizaje en conjunto basado en LASSO y BiLSTM.	Se utilizaron 29 variables provenientes de áreas macroeconómicas, activos financieros, índices de sentimiento y otros indicadores compuestos. Los datos abarcan desde enero de 2011 hasta junio de 2022, divididos en subconjuntos dentro de la muestra y fuera de muestra. Se seleccionaron datos relacionados con la reserva de divisas extranjeras, índices bursátiles, incertidumbre económica, entre otros. Mediante el método de selección LASSO, se redujo el número de variables a 6 más relevantes: - Reservas de divisas extranjeras (FER). - Índice del dólar estadounidense frente a una canasta de seis monedas extranjeras (DXY).	- Regresión de vectores de soporte (SVR). - Máquina de aprendizaje extremo (ELM). - Memoria a largo y corto plazo (LSTM). - Memoria a largo y corto plazo bidireccional (BiLSTM). - Máquina de aprendizaje extremo de kernel (KELM). - LASSO-SVR. - LASSO-ELM. - LASSO-LSTM. - LASSO-BiLSTM (propuesta). - LASSO-KELM.	El modelo LASSO-BiLSTM se basó en tres pasos: 1. Se seleccionan 29 variables de diferentes categorías. 2. Se utiliza LASSO para reducir el número de variables y seleccionar las más relevantes, en el estudio resultaron ser 6 variables. 3. Se emplea BiLSTM para predecir el tipo de cambio USD/CNY, utilizando las variables seleccionadas por LASSO. Las evaluaciones de precisión se realizaron mediante las métricas MAE, RMSE y MDA.	El modelo LASSO-BiLSTM superó a los demás modelos en la precisión de predicción a 1 paso para el tipo de cambio USD/CNY, con el menor MAE (0.051), RMSE (0.072) y un MDA más alto de 0.777. Asimismo, LASSO-BiLSTM superó a los otros 9 modelos en las previsiones a 3 y 6 pasos, así como en una verificación adicional donde se evaluó el dólar (USD) frente a la libra esterlina (GBP). Los resultados indican que LASSO-BiLSTM es el mejor método para pronosticar el tipo de cambio.

		<ul style="list-style-type: none"> - Índice bursátil de las 500 principales empresas en EE.UU. (S&P) - Incertidumbre de la política económica global (GEPU). - Incertidumbre de la política económica de China (CEPU). - Índice de búsqueda en Baidu (BI), que refleja el volumen de búsqueda sobre el tipo de cambio renminbi a dólar estadounidense (RMB/USD). 			
Wang J. et al. [67]	<p>El estudio aborda la predicción de tipos de cambio, que es una tarea desafiante debido a sus características no estacionarias y no lineales. Se propone un enfoque basado en aprendizaje profundo con selección de características bifásicas para la predicción de tipos de cambio multivariados, con el objetivo de mejorar la precisión en comparación con modelos convencionales.</p>	<p>Se utilizaron datos diarios de los tipos de cambio CNY/USD, USD/EUR y JPY/USD obtenidos del sitio "Fred Economic Data" (https://fred.stlouisfed.org/). El conjunto de datos abarca desde el 2 de enero de 2003 hasta el 18 de diciembre de 2020, con un total de 4380 observaciones. Los datos se dividieron en un conjunto de entrenamiento (80%) y un conjunto de prueba (20%).</p>	<ul style="list-style-type: none"> - Modelo de media móvil integrado autorregresivo (ARIMA) - Red neuronal de retropropagación (BPNN) - Memoria a largo y corto plazo (LSTM) - Bootstrap LS TM - Transformada Wavelet - Codificador automático apilado - LSTM (WT-SAE-LSTM) - GRU multi-variable - El modelo propuesto es un enfoque híbrido que combina Análisis de Espectro Singular (SSA), Codificador Automático Apilado (SAE), Eliminación Recursiva de Características con Máquinas de Vectores de Soporte (SVM-RFE) y memoria a largo y corto plazo bidireccional (Bi-LSTM) con mecanismo de atención. 	<p>El modelo propuesto consta de tres módulos: Preprocesamiento de series objetivo, ingeniería de características y módulo de pronóstico.</p> <p>1. Preprocesamiento de series objetivo: Existen dos procesos principales para las series objetivos: descomposición y reconstrucción. Se utiliza el análisis de espectros singulares (SSA) para descomponer la serie de tiempo en componentes significativos, lo que facilita la captura de características no lineales y no estacionarias. Luego el codificador automático apilado (SAE) se emplea para reconstruir los datos, eliminando ruido y reduciendo la dimensión de las características manteniendo la información útil.</p> <p>2. Ingeniería de características: Se emplea la eliminación recursiva de características mediante máquinas de vectores de soporte (SVM-RFE) para seleccionar las características más importantes entre 12 variables externas, reduciendo la complejidad de la estructura de datos y el tiempo de cálculo. Posteriormente, las 5 características seleccionadas se reconstruyen mediante codificadores automáticos (AE), introducidos en la parte de SAE.</p>	<p>El modelo propuesto demostró ser superior a los modelos comparados en términos de precisión de predicción en los tres conjuntos de datos diarios (CNY/USD, USD/EUR y JPY/USD).</p> <ul style="list-style-type: none"> - CNY/USD: MAE: 0.02117, RMSE: 0.0268, MAPE: 0.3123% - USD/EUR: MAE: 0.00107, RMSE: 0.0012, MAPE: 0.0935% - JPY/USD: MAE: 0.32708, RMSE: 0.4182, MAPE: 0.2999%

				<p>3. Módulo de pronóstico: Se utiliza un modelo Bi-LSTM con mecanismo de atención para procesar tanto las características reconstruidas como los modos intrínsecos (IMFs) reconstruidos, generando las predicciones finales.</p>	
Wang G. et al. [170]	Investigar la complementariedad de características profundas supervisadas y no supervisadas en la mejora de los resultados de predicción de un día en el mercado de divisas.	Se usaron tres conjuntos de datos de tasas de cambio diarios obtenidos del mercado de divisas, específicamente el euro estadounidense (EUR/USD), la libra esterlina frente al dólar estadounidense (GBP/USD) y el dólar estadounidense frente al yen japonés (USD/JPY), abarcando el periodo desde el 1 de diciembre de 2009 hasta el 31 de diciembre de 2019, con un total de 2631 observaciones. El 80% de estos datos se utilizó para entrenamiento y el 20% restante para prueba.	<ul style="list-style-type: none"> - Modelo de media móvil integrado autorregresivo (ARIMA). - Modelo generalizado de heterocedasticidad condicional autorregresiva (GARCH). - Máquinas de soporte vectorial para regresión (SVR). - Agregación de bootstrap o autodocimante (Bagging) - Boosting adaptativo (AdaBoost). - Subespacios Aleatorios (RS). - Memoria a largo y corto plazo profunda (Deep LSTM). - Red de creencias profundas (DBN). - Modelo de características supervisadas y no supervisadas con subespacios aleatorios (SUDF-RS). 	<p>El modelo propuesto SUDF-RS consta de tres fases principales:</p> <p>1. Adquisición de datos: Los datos originales del tipo de cambio se obtienen del mercado Forex. Los conjuntos de datos utilizados para cada método de extracción de características son los mismos.</p> <p>2. Extracción de características: Se extraen características profundas supervisadas utilizando redes de memoria a largo y corto plazo (LSTM) y características no supervisadas mediante redes de creencias profundas (DBN). Estas características se combinan para aprovechar su complementariedad en la predicción del tipo de cambio (FERP).</p> <p>3. Construcción del modelo: Se propone un nuevo método de subespacios aleatorios (RS) mejorado con árboles aleatorios (RF), en el que se adopta RF para identificar las capacidades predictivas discriminadoras de las características y asignarles diferentes pesos, asegurando la alta calidad de los subconjuntos de características. Posteriormente, cada subconjunto de características, seleccionado por RS mejorado, se utiliza para entrenar un aprendizaje base (base learner) correspondiente. Finalmente, se combinan los resultados de cada aprendizaje base</p>	<p>El modelo SUDF-RS mostró un rendimiento superior en comparación con los métodos de referencia (ARIMA, GARCH, SVR, Bagging, AdaBoost, RS, Deep LSTM y DBN) en los tres conjuntos de datos (EUR/USD, GBP/USD y USD/JPY). Específicamente, el modelo propuesto logró los valores más bajos en términos de error absoluto porcentual medio (MAPE) y error cuadrático medio (RMSE) promedio, validando su efectividad y estabilidad en la predicción de tasas de cambio.</p> <p>Valores de MAPE para SUDF-RS: EUR/USD: 0.302%, GBP/USD: 0.392%, USD/JPY: 0.252%.</p> <p>Valores de RMSE para SUDF-RS: EUR/USD: 0.448%, GBP/USD: 0.676%, USD/JPY: 0.374%.</p>

				promediando las predicciones para obtener el resultado final.	
Chang M.-J. & Matsuki T. [171]	Se explora la capacidad de predicción fuera de la muestra de los modelos de tipo de cambio utilizando datos macroeconómicos en tiempo real con tipos de cambio bilaterales y tasas de interés de corto plazo del Reino Unido y los países occidentales, es decir, Australia, Canadá, Nueva Zelanda y los EE. UU.	Se usaron datos macroeconómicos en tiempo real de países como Australia, Canadá, Nueva Zelanda, Estados Unidos y el Reino Unido. Estos datos incluyen variables financieras como el tipo de cambio y tasa de interés, y datos macroeconómicos en tiempo real como el PIB real y deflactor del PIB. Las fuentes de los datos incluyen el Banco de la Reserva Federal de Filadelfia, el Banco de Inglaterra, de la Organización para la Cooperación y el Desarrollo Económico (OECD), y otras bases de datos estadísticas nacionales y del Fondo Monetario Internacional (FMI).	- Modelo de regla de Taylor con política monetaria inercial (propuesta). - Modelo de caminata aleatoria.	El modelo propuesto de regla de Taylor con política monetaria inercial se basa en la predicción fuera de muestra de los tipos de cambio utilizando datos macroeconómicos en tiempo real. El modelo se estima utilizando métodos como mínimos cuadrados ordinarios (OLS), mínimos cuadrados no lineales (NLLS) y el método generalizado de momentos (GMM). Las variables clave incluyen la tasa de interés nominal, la tasa de inflación esperada y la brecha de producción esperada. La inercia de la política monetaria se modela a través de un mecanismo de ajuste parcial, donde la tasa de interés objetivo se ajusta gradualmente hacia un valor deseado en respuesta a los cambios en la inflación y la producción. Para evaluar el rendimiento del modelo, el estudio emplea un proceso de regresión rodante, donde el modelo se estima con los primeros 40 trimestres de datos y se realiza un pronóstico para un trimestre futuro. Luego, se descarta el primer trimestre de la muestra y se añade uno nuevo, repitiendo este proceso hasta que se cubren todos los datos disponibles. Los resultados se evalúan usando métricas como el error absoluto medio (MAE), el error cuadrático medio (RMSE) y el estadístico de Theil U, comparando el rendimiento del modelo con el de un proceso de caminata aleatoria. Además, se realizan pruebas de robustez como la incorporación de datos de precios de acciones y el análisis de posibles rupturas estructurales en las series temporales.	El modelo de predicción de tipos de cambio basado en la regla de Taylor, utilizando datos en tiempo real, superó al modelo de caminata aleatoria para los pares de divisas de los países occidentales y el Reino Unido. Los datos en tiempo real demostraron ser más adecuados que los revisados ex post, y se encontró que las suposiciones de coeficientes homogéneos y de reacciones simétricas de los tipos de cambio reales en el modelo estructural no eran válidas. La precisión del modelo se mantuvo durante períodos de desviaciones estructurales moderadas, mejorando aún más con la incorporación de los índices de precios de acciones.

Sahu K. K. et al. [172]	Mejorar la precisión en la predicción de las series temporales de tipo de cambio utilizando redes neuronales artificiales (ANNs) y técnicas de optimización evolutiva, el cual es difícil debido a la alta volatilidad y fluctuación de los tipos de cambio.	El estudio utiliza series temporales de tipo de cambio de seis pares de divisas de países del sur de Asia: Rupia India a Dólar Estadounidense (INR/USD), Yuan Chino a Dólar Estadounidense (CNY/USD), Rupia Pakistán a Dólar Estadounidense (PKR/USD), Taka de Bangladesh a Dólar Estadounidense (BDT/USD), Rupia Nepalí a Dólar Estadounidense (NPR/USD) y Rupia de Sri Lanka a Dólar Estadounidense (LKR/USD). Los datos fueron recolectados entre el 7 de febrero de 2019 y el 5 de agosto de 2019, obteniendo aproximadamente 150 puntos de datos por cada serie.	<ul style="list-style-type: none"> - Red neuronal de enlace funcional basado en evolución diferencial (DE-FLN). - Red neuronal de enlace funcional basado en algoritmo genético (GA-FLN). - Red neuronal de enlace funcional basado en optimización por enjambre de partículas (PSO-FLN). - Red neuronal de enlace funcional entrenado con el Algoritmo de Fuegos Artificiales (FWA-FLN) (propuesta). 	El modelo propuesto FWA-FLN-VDP incluye la incorporación de puntos de datos virtuales (VDPs) generados por el propio modelo para enriquecer los datos de entrenamiento. Se utiliza una ventana deslizante para generar conjuntos de datos de entrenamiento y prueba a partir de la serie temporal original. El proceso de predicción alterna entre la exploración de los VDPs y la predicción de los puntos de datos futuros. El entrenamiento del modelo se optimiza mediante el uso del Algoritmo de Fuegos Artificiales (FWA), que tiene un proceso iterativo de búsqueda y selección de las mejores soluciones en el espacio de búsqueda, mientras que la red neuronal de enlace funcional (FLN) se encarga de la generalización y predicción.	El modelo FWA-FLN-VDP mostró resultados superiores en comparación con los otros modelos híbridos considerados, logrando menores valores de error porcentual absoluto medio (MAPE) para la mayoría de las series de datos, tanto en predicciones de un día, una semana y un mes.
Xu H. et al. [173]	Predicción de los tipos de cambio de los pares de divisas USD-CNY, EUR-USD y GBP-USD mediante un modelo más preciso y confiable que pueda superar los métodos clásicos de predicción y de aprendizaje automático.	Se utilizaron datos históricos de los tipos de cambio para tres pares de divisas principales: Dólar estadounidense/Yuan chino (USD/CNY), Euro/Dólar estadounidense (EUR/USD) y Libra esterlina/Dólar estadounidense (GBP/USD). Además, se incorporó el índice de volatilidad CBOE (VIX) como una variable fundamental clave, con datos recolectados desde el 3 de julio de 2006 hasta el 15 de agosto de 2022.	<ul style="list-style-type: none"> - Memoria a largo y corto plazo (LSTM). - Unidad Recurrente Cerrada (GRU). - GRU con el índice de volatilidad CBOE (VIX). - GRU con el promedio móvil (MA). - GRU con VIX y MA (propuesta). 	La configuración experimental del modelo GRU con VIX y media móvil (MA) combina el análisis técnico y fundamental para la predicción de tipos de cambio. El modelo emplea una red neuronal GRU, ideal para procesar datos secuenciales como las series temporales de los tipos de cambio. Para enriquecer el análisis, se incorpora el índice de volatilidad VIX, un indicador clave del nivel de incertidumbre en los mercados financieros, lo que añade un componente fundamental al modelo. Además, se utiliza una técnica de media móvil (MA) para suavizar las series temporales históricas de los tipos de cambio, reduciendo el ruido y destacando las tendencias subyacentes. Los datos se dividen en conjuntos de entrenamiento y prueba en una proporción de 3:1. Durante el preprocesamiento, se	El modelo propuesto, GRU con VIX y media móvil, demostró una precisión significativamente superior en comparación con los demás enfoques evaluados, alcanzando valores de R^2 cercano a 0.95 para el par de divisa GBP-USD y un R^2 cercano a 0.99 para las divisas USD-CNY y EUR-USD.

				<p>aplica una media móvil de 30 días a los datos de los tipos de cambio para suavizar las fluctuaciones extremas y proporcionar una base más estable para la predicción. Este preprocesamiento no solo mejora la precisión del modelo, sino que también facilita la construcción de una estrategia de inversión sólida para generar retornos. En contraste, los datos del índice VIX se introducen sin este preprocesamiento, ya que el VIX ya es un índice de expectativas.</p> <p>Para entrenar el modelo, se utiliza el optimizador Adam (Estimación de Momento Adaptativo), conocido por su eficacia en modelos de redes neuronales profundas, junto con la función de activación Unidad Lineal Rectificada (ReLU), que ayuda a evitar el problema del gradiente desaparecido. La arquitectura del modelo sigue una configuración sencilla, que consta de una capa GRU con 256 unidades y una capa de salida.</p>	
<p>Arisanti R. & Puspita M. D. [45]</p>	<p>El estudio aborda la predicción del tipo de cambio entre el dólar estadounidense y la rupia indonesia (USD/IDR) utilizando un modelo no lineal de redes neuronales autorregresivas con variables exógenas (NARX NN), con el objetivo de analizar la relación entre el</p>	<p>El estudio utiliza datos históricos mensuales de la tasa de cambio USD/IDR y la tasa de interés BI 7-day Reverse Repo Rate desde enero de 2017 hasta julio de 2021. Los datos del tipo de cambio se obtuvieron de la web investing.com y los datos de la tasa de interés de referencia (BI 7DRR) de la web del Banco de Indonesia.</p>	<ul style="list-style-type: none"> - Red neuronal alimentada hacia adelante (FFNN) para la predicción de la variable exógena (BI 7DRR). - Red neuronal autorregresiva no lineal con variables exógenas (NARX NN) para predecir la tasa de cambio USD/IDR. El modelo propuesto es el NARX NN (13-5-1), que utiliza 13 neuronas de entrada, 5 neuronas ocultas en una capa y 1 neurona de salida. 	<p>La configuración del modelo propuesto incluye 13 neuronas de entrada que consisten en 12 retrasos del tipo de cambio y el valor actual de la tasa de interés BI 7-day Reverse Repo Rate, una capa oculta con 5 neuronas, y 1 neurona de salida que predice la tasa de cambio. La evaluación se realizó mediante el cálculo del error porcentual absoluto medio (MAPE).</p>	<p>El mejor modelo NARX NN alcanzó un R^2 ajustado de 96.39%. Los resultados de la predicción para los próximos 6 periodos (Abril 2021-Enero 2022) indican que con el aumento de la tasa de referencia (BI 7DRR), la rupia se fortalecerá frente al dólar, lo que se refleja en una tendencia a la baja en la tasa de cambio USD/IDR.</p>

	tiempo y el impacto de la tasa de interés de referencia de Indonesia BI 7-day Reverse Repo Rate (BI 7DRR) en la variable respuesta.				
Shen M.-L. et al. [174]	El objetivo es mejorar la precisión en la predicción de los tipos de cambio utilizando un enfoque híbrido de aprendizaje automático, lo que representa un desafío debido a las fluctuaciones causadas por eventos políticos y económicos.	Se utilizó datos mensuales de tipos de cambio desde enero de 1971 hasta diciembre de 2017 de siete países: Australia, Canadá, China, la Unión Europea, Japón, Taiwán y el Reino Unido. Los tipos de cambios fueron: - Dólar estadounidense - dólar australiano (USD-AUD). - Dólar estadounidense - libra esterlina británica (USD-GBP). - Dólar canadiense - dólar estadounidense (CAD-USD). - Renminbi chino - dólar estadounidense (RMB-USD). - Dólar estadounidense - euro (USD-EUR). - Yen japonés - dólar estadounidense (JPY-USD). - Nuevo dólar taiwanés - dólar estadounidense (NTD-USD).	- Caminata aleatoria (RW). - Suavización exponencial (ETS). - Modelo de media móvil integrado autorregresivo (ARIMA). - ARIMA estacional (SARIMA). - Red neuronal artificial (ANN). - Regresión de vectores de soporte (SVR). - SVR optimizado con optimización por enjambre de partículas (PSOSVR). - Modelo híbrido propuesto que combina la selección de característica, optimización de enjambre de partículas y regresión de vectores de soporte (FSPSOSVR).	El modelo FSPSOSVR incluye la selección de características mediante Random Forest (RF) para identificar las variables más relevantes, la optimización de los hiperparámetros del SVR mediante PSO, y la utilización de SVR para predecir los tipos de cambio. Se evaluó el rendimiento de predicción usando métricas como el MAPE y el RMSE.	El modelo FSPSOSVR logró una precisión de predicción significativamente superior en comparación con los siete modelos de referencia, obteniendo los valores más bajos de MAPE (2.296%) y RMSE (0.416) promedio en todas las monedas evaluadas.
Zhang Y. & Hamori S. [71]	El estudio examina si la combinación de modelos económicos tradicionales con metodologías modernas de aprendizaje automático puede superar el rendimiento predictivo de la	Los datos utilizados en el estudio son los siguientes: - Tasas de cambio JPY/USD, obtenidas de la búsqueda de series temporales del Banco de Japón (BOJ). - Para describir las macroeconomías, se utilizaron datos de la base de datos DataStream, incluyendo bonos de Estados Unidos, el Índice de Precios al Productor (IPP), el Índice de Precios al Consumidor (IPC), el stock de dinero de cada país (M1) y el Índice de Producción Industrial. - Bonos de Japón, obtenidos del Ministerio de Finanzas de Japón.	El estudio aplica modelos de aprendizaje automático como: Bosque aleatorio, máquina de vectores de soporte (SVM) y redes neuronales. Estos modelos se combinan con cuatro teorías fundamentales: Paridad de tasas de interés no cubiertas (UIRP), Paridad de poder adquisitivo (PPP), Modelo monetario y Regla de Taylor.	La configuración experimental se basa en un análisis de ventana deslizante para realizar pronósticos a un periodo adelante. Este enfoque implica realizar estimaciones de manera iterativa, desplazando la ventana de entrenamiento en cada análisis un periodo hacia adelante. El conjunto de datos completo abarca desde agosto de 1980 hasta agosto de 2019, utilizando un tamaño de ventana fijo de 421 periodos. Por ejemplo, la primera ventana tomada desde agosto de 1980 hasta agosto de 2015 se utilizó	Los resultados muestran que los modelos fundamentales combinados con técnicas de aprendizaje automático superan a la caminata aleatoria en términos de error cuadrático medio (RMSE).

	caminata aleatoria sin deriva ($\delta = 0$).	Todos los datos tienen una frecuencia mensual. Los bonos gubernamentales utilizados tienen diferentes vencimientos (1, 2, 3, 5, 7 y 10 años) para cada país.		para estimar septiembre de 2015. Por lo tanto, el modelo utiliza los datos de entrenamiento del período 1 al 421 para predecir el período 422 y luego utiliza los datos de entrenamiento del período 2 al 422 para predecir el período 423. Esto se repite hasta el final de la serie temporal. En total, el análisis de ventana móvil se ejecuta 47 veces para un modelo.	
Asadullah M. et al. [175]	Determinar si una combinación de modelos tradicionales y un modelo no lineal (NARDL) puede superar en precisión a los modelos univariados de series temporales, como ARIMA, el modelo Naïve y el suavizamiento exponencial, en la predicción de la tasa de cambio de la rupia pakistaní frente al dólar estadounidense (PKR/USD).	El estudio utiliza datos mensuales de la tasa de cambio PKR/USD desde enero de 2011 hasta diciembre de 2019. Las observaciones del año 2020 (M1 a M12) se reservaron para la previsión. Las variables explicativas incluyen la oferta monetaria, la balanza comercial, el producto interno bruto, la tasa de interés, la tasa de inflación, los precios del petróleo y los precios del oro.	<p>- ARIMA. - Modelo Naïve. - Modelo de suavizamiento exponencial. - Modelo autorregresivo con rezago distribuido no lineal (NARDL).</p> <p>Además, el estudio incluye varias combinaciones de estos modelos para mejorar la precisión.*</p> <p>Combinaciones de dos vías:</p> <ul style="list-style-type: none"> • AR-ES • AR-N • AR-ND • ES-N • ES-ND • N-ND <p>Combinaciones de tres vías:</p> <ul style="list-style-type: none"> • AR-ES-N • AR-ES-ND • ES-N-ND • AR-N-ND <p>Combinaciones de cuatro vías:</p> <ul style="list-style-type: none"> • AR-N-ES-ND <p>*AR=ARIMA, N= Naïve, ES= Suavizamiento exponencial, ND= Modelo autorregresivo con rezago distribuido no lineal.</p>	Se utiliza un enfoque de combinación de modelos para la predicción, evaluando los modelos de manera individual y en combinaciones de dos, tres y cuatro vías.	El modelo NARDL superó a los tres modelos univariados individuales, obteniendo el valor de MAPE más bajo (0.292) en la predicción de la tasa de cambio PKR/USD.
Panda M. M. et al. [176]	Predicción del tipo de cambio de divisas extranjeras (AUD/JPY, NZD/USD y GBP/JPY)	El experimento se llevó a cabo utilizando tres pares de divisas principales: AUD/JPY, NZD/USD y GBP/JPY. Para realizar los experimentos, se recopilaron datos del 2 de enero de 2001 al 31 de	<p>- ARIMA. - Perceptrón multicapa (MLP). - Regresión Lineal (LR). - Redes neuronales convolucionales con una capa de regresión</p>	El modelo CNN-RF está compuesto por cuatro capas convolucionales, tres capas de agrupación, una capa completamente conectada y una capa de lectura. Inicialmente, los	El modelo CNN-RF mostró un rendimiento superior en comparación con los modelos ARIMA, MLP y LR en cuanto a precisión. Los

	<p>mediante un modelo preciso CNN-RF lo cual es crucial para comerciantes e inversores que desean conocer el comportamiento de la moneda nacional frente a otras.</p>	<p>mayo de 2020 para AUD/JPY y GBP/JPY y del 1 de enero de 2003 al 31 de mayo de 2020 para NZD/USD. Los datos diarios incluyen el precio de apertura, precio de cierre, precio mínimo, precio máximo y volumen.</p>	<p>de bosque aleatorio (CNN-RF) (propuesta)</p>	<p>datos se preprocesan mediante una normalización estándar (0,1) para garantizar que las entradas estén en un rango uniforme. A continuación, se seleccionan las características y etiquetas relevantes para el entrenamiento. Para reducir la dimensionalidad y mejorar la eficiencia del modelo, se utiliza el algoritmo de Análisis de Componentes Principales (PCA). Los datos de entrada consisten en registros tomados cada minuto durante un período de 24 horas.</p> <p>Cada una de las capas convolucionales está seguida por una capa de agrupación máxima, de la siguiente manera: la capa convolucional 1 es seguida por la capa de agrupación 1, la capa convolucional 2 es seguida por la capa de agrupación 2 y las capas convolucionales 3 y 4 son seguidas por la capa de agrupación 3. Este proceso reduce la dimensionalidad de los mapas de características generados por las capas convolucionales. Posteriormente, el modelo emplea una capa completamente conectada para procesar las características extraídas. En la capa de lectura (salida), se utiliza una capa de regresión de bosque aleatorio, que se encarga de realizar la predicción final.</p> <p>Para el entrenamiento, se utiliza el optimizador Adam con el fin de minimizar la pérdida mediante la Raíz del Error Cuadrático Medio (RMSE). El modelo se entrena con un tamaño de lote de 256 y una tasa de abandono</p>	<p>valores promedio de R^2 para los tres pares de divisas fueron de 0.9616 para AUD/JPY, 0.9640 para NZD/USD y 0.9620 para GBP/JPY, lo que confirma que el modelo propuesto es el más preciso para predecir el tipo de cambio de divisas.</p>
--	---	---	---	---	--

				(dropout) del 20% para evitar el sobreajuste. El entrenamiento se lleva a cabo durante 10 épocas, con una tasa de aprendizaje inicial de 0.003. Los datos se dividen en un 80% para el entrenamiento y un 20% para la validación, lo que permite evaluar eficazmente el rendimiento del modelo.	
Wang G. et al. [177]	Poca investigación sobre el efecto complementario de las características superficiales y profundas, y el potencial predictivo conjunto de múltiples características por lo que se propone un nuevo método de aprendizaje de conjunto, el subespacio aleatorio disperso lineal adaptativo (ALS-RS), basado en el efecto complementario de las características superficiales y profundas para predecir con precisión el tipo de cambio de divisas entre el euro/dólar estadounidense	Se utilizaron conjuntos de datos históricos de precios (apertura, cierre, máximo y mínimo) de cuatro pares de divisas (EUR/USD, GBP/USD, JPY/USD y MXN/USD) para el análisis empírico. Estos datos fueron obtenidos del sitio web investing.com. Cada conjunto de datos contiene 2608 observaciones, cubriendo el periodo del 1 de enero de 2010 al 31 de diciembre de 2019, y se dividió en dos partes: un conjunto de entrenamiento (del 1 de enero de 2010 al 29 de diciembre de 2017) y un conjunto de prueba (del 1 de enero de 2018 al 31 de diciembre de 2019).	<ul style="list-style-type: none"> - Modelo de media móvil integrado autorregresivo (ARIMA). - Árbol de decisión (DT). - Regresión de soporte vectorial (SVR). - Agregación de bootstrap o autodocimante (Bagging). - Algoritmo de Boosting adaptativo (Adaboost) - Bosque aleatorio (RF). - Red neuronal artificial con modelo de heterocedasticidad condicional autoregresiva generalizada(ANN-GARCH) - Subespacio aleatorio (RS). - Modelo de memoria a largo y corto plazo con subespacio aleatorio (LSTM-RS). - Subespacio aleatorio disperso lineal adaptativo (ALS-RS) (propuesta). 	La configuración experimental del modelo ALS-RS se centra en la adquisición y procesamiento de datos históricos del tipo de cambio de cuatro pares de divisas, que incluyen datos de precios. El modelo sigue un proceso de extracción de características de estos datos históricos, utilizando características superficiales (como retardos temporales e indicadores técnicos) y características profundas, las cuales son extraídas mediante una red neuronal recurrente bidireccional (Bi-GRU). Esta red permite capturar patrones complejos en secuencias temporales, mejorando la precisión en la predicción. El modelo ALS-RS emplea un método de subespacio aleatorio mejorado, junto con una técnica denominada disperso lineal adaptativo (ALS), que se encarga de ponderar las características, optimizando la selección de aquellas más relevantes para el modelo y descartando las que no aportan valor. A partir de esta técnica, se generan aprendices base utilizando el algoritmo de Regresión de Vectores de Soporte (SVR), los cuales trabajan con subconjuntos de las características seleccionadas. Los resultados finales del modelo se obtiene	El modelo ALS-RS superó a los otros modelos en términos de precisión en la predicción de los tipos de cambio, obteniendo los mejores resultados en las métricas de error absoluto porcentual medio (MAPE) y error cuadrático medio (MSE). En cuanto a la métrica de cambio de dirección (DS), el modelo obtuvo los mejores resultados en los pares de divisas GBP/USD, JPY/USD y MXN/USD, aunque fue superado por el modelo LSTM-RS en el par de divisas EUR/USD.

	<p>ense (EUR/USD), libra esterlina/dólar estadounidense (GBP/USD), yen japonés/dólar estadounidense (JPY/USD) y peso mexicano/dólar estadounidense (MXN/USD).</p>			<p>mediante el promedio de las predicciones de estos aprendices. Para evaluar su rendimiento, se utilizaron métricas como el error absoluto porcentual medio (MAPE), el error cuadrático medio (MSE) y el cambio direccional (DS).</p>	
<p>Yasar H. & Kilimci Z. H. [178]</p>	<p>Mejorar la precisión en la predicción del tipo de cambio entre el dólar estadounidense y la lira turca (USD/TRY).</p>	<p>El estudio emplea dos tipos de conjuntos de datos: el primero proviene de contenido extraído de Twitter, tanto en inglés como en turco, utilizando hashtags relacionados con el tipo de cambio USD/TRY. El segundo proviene del Banco Central de la República de Turquía, que proporciona las tasas de cambio oficiales. Todos los datos se recopilaron entre el 1 de enero de 2018 y el 31 de diciembre de 2018, en formato de texto.</p>	<p>Para el análisis de sentimiento (FSA), se utilizaron métodos de incrustación de palabras como Word2Vec, GloVe, fastText; y, modelos de aprendizaje profundo como CNN, RNN y LSTM.</p> <p>Para el análisis de series temporales (TSA), se emplearon modelos de suavizamiento exponencial simple (SES), tendencia lineal de Holt (HLT), Holt-Winters multiplicativo (HWC) y aditivo (HWT), y modelos autorregresivos integrados de media móvil (ARIMA).</p> <p>El modelo híbrido integra el análisis de sentimiento mediante LSTM + GloVe y el análisis de series temporales utilizando HLT, lo que permite mejorar la precisión de la predicción del tipo de cambio USD/TRY (propuesta).</p>	<p>La arquitectura del modelo propuesto se construye en tres etapas en forma de obtención y modelado de datos de texto para el análisis del sentimiento financiero, obtención y modelado de datos numéricos para el análisis de series temporales y combinación de los dos modelos como una simetría.</p> <p>1. Análisis de sentimiento financiero (FSA): Se recopilan datos textuales de Twitter sobre el tipo de cambio (usando hashtags relevantes) y se procesan mediante técnicas de preprocesamiento, como la limpieza de puntuación y caracteres no deseados. Luego, estos datos textuales se transforman en vectores utilizando modelos de embeddings de palabras (Word2Vec, GloVe, fastText), que son posteriormente introducidos en modelos de aprendizaje profundo como CNN, RNN y LSTM para clasificar el sentimiento como positivo o negativo.</p> <p>2. Análisis de series temporales (TSA): Se utilizan los datos históricos de precios del tipo de cambio USD/TRY proporcionados por el Banco Central de Turquía.</p>	<p>El modelo híbrido alcanzó una precisión del 95.87% en la predicción del tipo de cambio USD/TRY utilizando el modelo de tendencia lineal de Holt para el análisis de series temporales. Además, en el análisis de sentimiento, obtuvo una precisión del 86.03% para los datos en turco y del 79.01% para los datos en inglés, empleando la combinación de LSTM y GloVe.</p>

				<p>Estos datos se analizan mediante diferentes modelos de series temporales como el suavizamiento exponencial simple (SES), la tendencia lineal de Holt (HLT) y ARIMA, con el fin de predecir el tipo de cambio futuro.</p> <p>3. Combinación del análisis de sentimiento y series temporales: Finalmente, los resultados del análisis de sentimiento y el análisis de series temporales se combinan para formar un modelo híbrido que proporciona predicciones más robustas y precisas sobre el tipo de cambio USD/TRY.</p> <p>Los mejores resultados fueron obtenidos utilizando la combinación de LSTM + GloVe para el análisis de sentimiento y el modelo de tendencia lineal de Holt (HLT) para las series temporales, tanto en los conjuntos de datos en turco como en inglés, consolidando la precisión y consistencia del sistema.</p>	
Kausar R. et al. [68]	Se aborda el problema de la predicción precisa de precios en el mercado Forex, específicamente la tasa de cambio entre el dólar estadounidense y la rupia pakistaní (USD/PKR).	En el estudio se utilizan datos de precios diarios del tipo de cambio USD/PKR para evaluar la eficacia del modelo híbrido propuesto. Los datos históricos de precios de apertura, máximo, mínimo y cierre (OHLC) del 4 de marzo de 1992 al 20 de febrero de 2023 se obtuvieron de investing.com.	<ul style="list-style-type: none"> - GRU-ATCN. - VMD-GRU-ATCN. - CEEMDAN-GRU-ATCN. - VMD-LSTM-ATCN. - VMD-CEEMDAN-GRU-ALSTM. - VMD-CEEMDAN-GRU-ATCN (w/o TIs). - VMD-CEEMDAN-GRU-ATCN (propuesta). 	<p>El enfoque híbrido VMD-CEEMDAN-GRU-ATCN combina varias técnicas avanzadas de descomposición y predicción de series temporales para mejorar la precisión en la predicción de precios de Forex USD/PKR. Las técnicas empleadas son:</p> <p>1. Descomposición modal variacional (VMD): Esta técnica descompone la serie de tiempo original en componentes modales individuales (VMFs). Luego, se genera una serie residual al restar estos VMFs de la secuencia original.</p> <p>2. Descomposición modal empírica de conjunto completo con ruido</p>	El modelo híbrido propuesto demostró una precisión superior en comparación con otros modelos de referencia. Se evaluó el modelo utilizando métricas como el MAE, SMAPE, RMSE y MAPE, mostrando un rendimiento más robusto y consistente para la predicción del tipo de cambio USD/PKR tanto en predicciones a corto como a largo plazo

				<p>adaptativo (CEEMDAN): Se realiza una segunda fase de descomposición en la serie residual utilizando la técnica CEEMDAN, lo que permite obtener un nuevo conjunto de subseries de residuales (IMFs).</p> <p>3. Unidad recurrente cerrada (GRU): Se utiliza el modelo GRU para predecir los componentes modales producidos mediante la descomposición de la serie inicial (VMFs) y la descomposición del término residual (IMFs), que juntos forman un conjunto de predictores.</p> <p>4. Red convolucional temporal basada en la atención (ATCN): El último paso consiste en formar una matriz de entrada final que combine precios OHLC, indicadores técnicos y el agregado de resultados de todos los submodelos. Esta matriz se utiliza para entrenar el modelo ATCN, que genera las predicciones finales.</p> <p>Esta integración permite capturar patrones complejos en los datos financieros y mejorar la efectividad del pronóstico a través de una descomposición y análisis más detallado de las series temporales.</p>	
Wazeer E. A. A.-D. & Hameed L. M. A. [179]	Debido a las fluctuaciones en los últimos años en el tipo de cambio del dólar estadounidense frente al dinar iraquí, ha	Se utilizaron datos del tipo de cambio del dólar estadounidense frente al dinar iraquí, obtenidos del Banco Central de Irak, que abarca el periodo del 31 de agosto de 2010 al 31 de marzo de 2021.	El estudio se centró en modelos ARIMA usando la metodología Box-Jenkins: - ARIMA (1,1,0). - ARIMA (1,1,1). - ARIMA (0,1,1). - ARIMA (2,1,0). - ARIMA (2,1,1).	La configuración experimental incluyó el análisis de la estacionariedad de la serie temporal utilizando pruebas como la Augmented Dickey-Fuller (ADF). Posteriormente, se diagnosticó el modelo usando la metodología Box-Jenkins, se calcularon las diferencias necesarias para estabilizar la serie y	El modelo ARIMA (1,1,0) fue identificado como el más efectivo para predecir el tipo de cambio del dólar frente al dinar iraquí para el año 2022.

	<p>habido un impacto negativo en la economía de Irak, lo que ha provocado un desequilibrio económico. Por esta razón, el objetivo del estudio es identificar el mejor modelo para prever el tipo de cambio y contribuir a la estabilidad económica del país.</p>			<p>se generaron las funciones de autocorrelación y autocorrelación parcial para identificar el orden del modelo. Finalmente, el modelo ARIMA(1,1,0) fue seleccionado por ser el más eficiente para predecir el tipo de cambio, de acuerdo con los criterios ADF, BIC, RMSE y MAPE.</p>	
--	--	--	--	--	--

Apéndice E. Estudios para la predicción de la inflación

Autores	Problema abordado	Conjunto de datos	Modelo propuesto	Configuración experimental	Resultados obtenidos
Constantino M. et al. [39]	Analizar y predecir la tasa de inflación en Brasil entre 2007 y 2017	Serie temporal de la tasa de inflación entre 2007 y 2017	- ARIMA - SARIMA	El procedimiento metodológico comienza con un análisis exploratorio de los datos históricos de la inflación, medida por el Índice Nacional de Precios del Consumidor Amplo (IPCA). Este análisis inicial tiene como objetivo identificar patrones, tendencias y estacionalidad en la serie temporal de la inflación. Posteriormente, se procede con la modelización econométrica utilizando el modelo SARIMA, diseñado para capturar tanto las componentes estacionales como no estacionales de la tasa de inflación. Para validar el modelo, se comparan las previsiones generadas con los datos reales del IPCA, buscando comportamientos similares entre ambos. Este proceso de comparación permite ajustar el modelo y obtener estimaciones más precisas sobre la evolución futura de la inflación.	El resultado obtenido mostró que el modelo SARIMA tiene una eficiencia del 95% en la predicción de la tendencia de la tasa de inflación para los próximos años en Brasil. La previsión señala un aumento en la tasa de inflación, reflejando una probable recuperación económica del país.
Wang M. et al. [62]	El objetivo es prever la tasa de inflación en China utilizando un modelo variable en el tiempo para lograr una alta precisión, en el contexto de la transición de un período de rápido crecimiento en las últimas décadas a una etapa de "nueva	La tasa de crecimiento del índice de precios al consumidor (IPC) se utiliza como una medida de la inflación, por lo que se emplearon datos mensuales del IPC de China, que abarcan desde enero de 1995 hasta diciembre de 2017, con un total de 276 observaciones. Los modelos se prueban tanto con estos datos reales como con datos simulados.	- Modelo autorregresivo con coeficiente funcional (FAR) basado en el método de estimación B-splines. - Modelo autorregresivo de media móvil (ARMA).	El modelo FAR (p, d) se ajusta utilizando el método de estimación basado en B-splines, y se seleccionaron $p = 4$ y $d = 2$ basados en el criterio de información de Akaike (AIC). Se probaron diferentes grados de B-spline y números de nudos interiores, concluyendo que la combinación óptima era un B-spline de grado 2 con un nudo interior, lo que redujo la complejidad computacional.	Los resultados de la predicción muestran que el modelo FAR, basado en el método de estimación con B-splines, tiene un mejor desempeño que el modelo ARMA. El FAR(4,2) superó al ARMA(5,5) en la predicción de la inflación en China durante periodos estables, como la 'Nueva Normalidad', mientras que el ARMA tuvo un mejor rendimiento en periodos más volátiles. El FAR(4,2) fue más preciso en las predicciones a largo plazo y en

	normalidad " de desarrollo económico.				fases de menor fluctuación.
Yang C. y Guo S. [63]	La inflación es un indicador que impacta las políticas monetarias y las decisiones de inversión, por lo que se predice en China utilizando un modelo basado en aprendizaje profundo.	<p>Las muestras utilizadas en el estudio están compuestas por datos mensuales recopilados del sitio web económico de China y de la base de datos Wind.</p> <p>Las 11 variables principales que forman el vector de características utilizado para describir la inflación y entrenar el modelo GRU-RNN son: Tasa de crecimiento interanual del Índice de Precios al Consumidor (CPI), tasa de crecimiento interanual del suministro de dinero restringido (M1), tasa de crecimiento interanual del suministro de dinero amplio (M2), tasa de préstamo interbancaria a 7 días (RATEST), tasa de crecimiento interanual del aumento industrial (IVA), tasa de crecimiento interanual de las ventas minoristas totales de bienes de consumo (C), índice de auge de la vivienda nacional (HINDEX), tasa de crecimiento acumulada interanual de la inversión en desarrollo inmobiliario (HINVEST), tasa de crecimiento interanual del área de construcción comercial iniciada (HSTARTS), índice Shanghai y Shenzhen 300 (STOCK) y paridad central del RMB frente al dólar estadounidense (EXC).</p>	<ul style="list-style-type: none"> - Redes neuronales recurrentes con unidad recurrente cerrada (GRU-RNN) (propuesta). - ARMA. - BVAR. - BP. 	<p>El proceso principal de predicción de la inflación basado en GRU-RNN consta de los siguientes pasos: (1) adquisición de datos de entrenamiento, donde se construyen los vectores de características que describen la inflación como entradas y se utilizan los indicadores de inflación como salidas; (2) establecimiento de la red GRU-RNN con parámetros preestablecidos, donde se construye la estructura de la red y se seleccionan la función de activación, la función objetivo, el algoritmo de optimización y la función de evaluación, además de configurar hiperparámetros como el intervalo de muestreo, el número de iteraciones de entrenamiento y la tasa de aprendizaje. Los pesos y sesgos de la red se inicializan; (3) entrenamiento de la red GRU-RNN, ajustando parámetros como los pesos y los desplazamientos hasta que la función objetivo cumpla con los requisitos; y (4) estimación del indicador de inflación, donde los vectores de características recién recopilados se ingresan en la red entrenada y se genera el valor estimado del indicador de inflación.</p>	<p>El modelo GRU-RNN mostró un mejor desempeño en la predicción del CPI en comparación con los modelos de referencia, con valores de error más bajos (MSE=0.359, MAPE= 0.460%, SMAPE= 0.458%)</p>
Verne J.-F. [85]	Prever el comportamiento no lineal de la tasa de inflación en el Líbano en el contexto de las fluctuaciones económicas desde diciembre	<p>El conjunto de datos utilizado corresponde a la tasa de inflación mensual, calculada a partir del Índice de Precios al Consumidor (IPC) entre diciembre de 2008 y enero de 2022, obtenida de la Administración Central de Estadísticas.</p>	<ul style="list-style-type: none"> - Modelo autorregresivo integrado de medias móviles estacional (SARIMA). - Modelo Autorregresivo No Lineal (AR). 	<p>El modelo NAR fue configurado con dos entradas: $x_i = \{Y_{t-1}, Y_{t-12}\}$ (siendo Y_{t-1} el término autorregresivo y Y_{t-12} el orden estacional) y una salida Y_t. h_1 y h_2 son las dos neuronas ocultas incluidas en una capa oculta, h.</p> <p>El modelo NAR(1, 1, 2) fue ajustado con una única capa oculta con dos neuronas, utilizando la</p>	<p>El modelo NAR de tipo feedforward da mejores resultados que el modelo lineal SARIMA en cuanto a la bondad de ajuste y la precisión de la previsión de la tasa de inflación en el Líbano.</p>

	de 2008 hasta enero de 2022, utilizando modelos de redes neuronales artificiales (ANN).			función logística como función de activación.	
Chow H.-K. [180]	Previsión de la inflación de Singapur mediante un índice de condiciones financieras (FCI)	Se utilizaron datos trimestrales de varias variables financieras de Singapur, abarcando el período desde el primer trimestre de 1978 hasta el segundo trimestre de 2011. Las variables seleccionadas para su inclusión en el índice de Singapur incluyen: tasas de interés, tipo de cambio nominal efectivo, expansión crediticia, precios de acciones (Índice compuesto de Straits Times) y precios de viviendas	Se utilizó un modelo de autorregresión vectorial (VAR) monetario para analizar las relaciones entre las variables financieras y la inflación. El modelo propuesto, denominado Índice de Condiciones Financieras de Singapur (SFCI), se desarrolló utilizando una suma ponderada de las variables financieras clave.	El Índice de Condiciones Financieras de Singapur (SFCI) se construyó asignando pesos a cada variable financiera en función de las respuestas acumulativas de la inflación ante un shock de una desviación estándar en cada variable. El modelo VAR estimó el impacto de cada variable sobre la inflación, y los pesos reflejan su influencia relativa.	El índice SFCI demostró ser un buen predictor de la inflación, mejorando significativamente el rendimiento de las predicciones fuera de muestra cuando se incluyó en modelos autorregresivos. Redujo los errores de pronóstico (RMSE) entre un 8% y un 13% en horizontes de predicción de hasta un año, lo que muestra su capacidad para guiar la formulación de políticas monetarias en Singapur.
Mitra D. y Rashid M. [181]	Precisión comparativa de los pronósticos de inflación en Canadá	Los datos incluyen 3 variables: inflación, tipo de cambio y tasa de utilización de la capacidad manufacturera. Los datos se obtienen del Sistema Canadiense de Gestión de Información Socioeconómica (CANSIM) y de las bases de datos del Banco de Canadá. El conjunto de datos utilizado en el estudio abarca desde el primer trimestre de 1962 (1962:1) hasta el cuarto trimestre de 1986 (1986:4)	<ul style="list-style-type: none"> - Modelo de autorregresión vectorial (VAR). - Modelo autorregresivo integrado de media móvil (ARIMA). - Modelo de expectativas estáticas. Portafolio de pronóstico: <ul style="list-style-type: none"> - VAR+ARIMA - VAR+Static - ARIMA+Static -VAR+ARIMA+Static 	La configuración experimental del modelo VAR se basa en un conjunto de datos provenientes de CANSIM y de las bases de datos del Banco de Canadá, lo que garantiza la relevancia y precisión de la información utilizada. Para generar las previsiones, el modelo emplea un enfoque de ventana deslizante (rolling window). En el Panel A, tras entrenar el modelo con datos desde el primer trimestre de 1962 (1962:1) hasta el final del período de estimación inicial (1971:4), se avanza un trimestre y se reestima el modelo con la información más reciente disponible, permitiendo ajustar continuamente el modelo y mantener la precisión del pronóstico a corto plazo (un trimestre adelante). En el Panel B, el modelo se ajusta para hacer previsiones a mediano	<ul style="list-style-type: none"> - El modelo VAR mostró superioridad en periodos de alta volatilidad inflacionaria, mientras que los modelos ARIMA y de expectativas estáticas funcionaron mejor en periodos de estabilidad. El enfoque de combinación de modelos (portafolio) redujo significativamente los errores de pronóstico en comparación con el uso de modelos individuales.

				<p>plazo (cuatro trimestres adelante), avanzando cuatro trimestres en cada paso antes de reestimar el modelo con la información más reciente disponible. Este enfoque permite evaluar la precisión del modelo tanto en horizontes de corto como de mediano plazo. Además, el estudio evalúa la estabilidad del modelo en distintos contextos económicos, utilizando la descomposición de Theil para analizar los errores de predicción y determinar si estos se deben a sesgos o a variaciones no sistemáticas. Para medir la precisión del modelo, se aplican métricas como el error cuadrático medio (RMSE), el error absoluto medio (MAE) y la estadística U de Theil, que descompone los errores en sus proporciones de sesgo, regresión y perturbación. Las sub-muestras seleccionadas abarcan diferentes niveles de estabilidad y volatilidad inflacionaria, capturando diversas fases económicas para evaluar si los agentes económicos tienden a usar modelos más sofisticados en periodos de alta volatilidad. Esta configuración experimental permite una evaluación integral y precisa del desempeño del modelo VAR en distintos escenarios inflacionarios.</p>	
Arisanti R. et al. [69]	Proporcionar información sobre la credibilidad de una posible recesión en los próximos años al evaluar la precisión de las predicciones inflacionarias.	Los datos constan de un período de 24 años, desde 1998 hasta 2021. El conjunto de datos consta de 1 variable principal y 5 variables exógenas: Tasa de interés real, crecimiento del PIB per cápita, gasto de consumo final, crecimiento de la población y exportaciones de bienes y servicios.	<ul style="list-style-type: none"> - Red Neuronal No Lineal Autorregresiva con Variables Exógenas (NARX-NN) (propuesta). - Red Neuronal de Alimentación Directa (FFNN). 	<p>La configuración experimental del modelo NARX NN utiliza una arquitectura serie-paralelo. El conjunto de datos se divide en un 85% para entrenamiento (1998-2017) y un 15% para pruebas (2018-2021). Na vez realizada la partición, se estableció la arquitectura de la red NARX-NN para predecir la inflación como variable de respuesta. La arquitectura de la red fue la siguiente:</p>	El mejor modelo identificado fue NARX NN (9-5-1). La prueba del modelo NARX NN con datos de la tasa de inflación dio como resultado un RMSE de 3,375 y un MAE de 2,552. Las predicciones para los próximos cinco años (2022-2026) indican una tendencia al alza en la tasa de inflación, sugiriendo la posibilidad de una

				<p>- Neuronas de entradas: 9 neuronas que incluyen región, nombre del país, rezagos 1 y 2 de la inflación, valor actual de la tasa de interés real, crecimiento del PIB per cápita, gasto de consumo final, crecimiento poblacional y exportaciones de bienes y servicios.</p> <p>- Capa oculta: 1 capa, y el número de neuronas en esta capa se determinó mediante prueba y error, seleccionando la cantidad que produjo el menor valor de error.</p> <p>- Neuronas ocultas: Se probaron configuraciones de 1, 5, 10 y 15 neuronas para determinar la que ofrecía el mejor rendimiento.</p> <p>- Neuronas de salida: 1 neurona, ya que solo se predice la tasa de inflación.</p> <p>Después de definir la arquitectura de la red, se procedió al entrenamiento, prueba y evaluación del modelo. Antes de iniciar el entrenamiento, se normalizaron los datos utilizando un escalamiento estándar. En este estudio, se emplea la función de activación tanh en la capa oculta durante el entrenamiento y una función de activación lineal en la capa de salida. El rendimiento del modelo se evalúa mediante el cálculo de los valores de RMSE y MAE para cada configuración de red con un número específico de neuronas ocultas (1, 5, 10 y 15).</p>	próxima recesión económica.
Ferreira D. y Palma A. A. [182]	Predicción de la inflación en Brasil utilizando un enfoque de curva de Phillips generalizada.	El conjunto de datos incluye datos mensuales de Brasil desde enero de 2003 hasta octubre de 2013, abarcando el Índice Nacional de Precios al Consumidor Amplio (IPCA) como medida de la inflación junto con ocho predictores potenciales como la tasa de desempleo, el crecimiento	<p>- El Promedio Dinámico de Modelos (DMA).</p> <p>- La Selección Dinámica de Modelos (DMS).</p>	El modelo DMA se basa en un enfoque de curva de Phillips reducida, con los datos ajustados estacionalmente y transformados para asegurar su estacionariedad. El período de muestra fue seleccionado para evitar una ruptura metodológica importante en la encuesta	Las especificaciones dinámicas proporcionan buenas predicciones de inflación para todos los horizontes de pronóstico, destacando la importancia de las características variables en el tiempo. Hay

		del PIB real, la utilización de la capacidad industrial, el índice de precios de las materias primas, el tipo de cambio nominal, el índice de precios de importación, las expectativas de inflación y la tasa de interés a corto plazo.		de desempleo en 2002. Además, se utilizó el método X-12-ARIMA para ajustar estacionalmente las series temporales.	evidencia de que la relación de la curva de Phillips a corto y largo plazo no se aplica en Brasil, mientras que el impacto del tipo de cambio en la inflación a corto y mediano plazo ha disminuido en años recientes.
Kanda P. T. et al. [82]	Predicción de la inflación en Sudáfrica utilizando modelos no lineales, evaluando su rendimiento o con una función de pérdida ponderada para medir la precisión en diferentes entornos económicos extremos y horizontes de pronóstico en Sudáfrica.	Se utilizaron las tasas de crecimiento mensual del Índice de Precios al Consumidor (IPC) de Sudáfrica, ajustadas estacionalmente mediante el método Census X-12. Los datos fueron obtenidos de la Base de datos Financiera Mundial y abarcan el período de febrero de 1921 a enero de 2013, con un total de 1104 observaciones.	<ul style="list-style-type: none"> - Árbol de Modelo Lineal Local (LoLiMoT) (propuesta). - Modelo Autorregresivo (AR). - Perceptrón Multicapa (MLP). - Modelo Autorregresivo No Lineal (NAR). - Algoritmo Genético (GA). - Modelo de Combinación Promedio (MEAN). 	El modelo LoLiMoT se basa en el uso de una estrategia de "divide y vencerás". El modelo divide el problema complejo en subproblemas más simples que se pueden resolver mediante modelos lineales independientes. El espacio de entrada se divide en pequeños subespacios lineales utilizando funciones de validez difusa. El modelo combina parámetros no lineales (medias y desviaciones de funciones de validez gaussianas) y parámetros lineales (como neuronas difusas) para generar predicciones precisas.	El modelo LoLiMoT demostró ser el más eficaz en la predicción de la inflación en Sudáfrica en la mayoría de los horizontes de pronóstico, superando consistentemente a otros modelos en la mayoría de las configuraciones de pérdida ponderada evaluadas.
Mirza N. et al. [83]	Predicción de la inflación en economías emergentes, se comprueba si los modelos de Aprendizaje Automático superan a los modelos tradicionales de predicción. También se investiga el impacto de incluir las reservas de divisas (FXReserves) en los	Se utilizó un conjunto de datos que comprende observaciones mensuales que abarca un período de 20 años (del 1 de junio de 2003 al 1 de junio de 2023) para estimar empíricamente la relación econométrica entre las variables modeladas, con un enfoque en el caso de Pakistán.	<ul style="list-style-type: none"> - Regresión múltiple. - ARMA. - ARIMA. - Bosque aleatorio. - SVR. - K vecino más cercano. - Aumento de gradiente. - Aumento de gradiente extremo (XGBoost). <p>Estos modelos de machine learning (ML) se combinan con la inclusión explícita de las reservas de divisas.</p>	La configuración experimental del modelo propuesto en el estudio se desarrolla en tres etapas para evaluar como diferentes variables afectan su precisión predictiva: En primer lugar, el modelo 1 se basa en variables tradicionales como la tasa de interés, la oferta monetaria y la producción industrial. Este modelo sirve como la base inicial para las predicciones. A continuación, se amplía en el modelo 2, que añade el tipo de cambio para capturar su impacto en la inflación junto a las variables del modelo 1. Finalmente, se desarrolla el modelo 3 (propuesta), que extiende aún más el modelo 2 al incorporar las	Los resultados muestran que los modelos de ML superan consistentemente a los modelos tradicionales en la predicción de la inflación. En particular, Random Forest y Gradient Boosting se destacaron como los más precisos. Además, se comprobó que la inclusión de las reservas de divisas mejora la precisión de los modelos de predicción, validando la hipótesis de que las FXReserves son un determinante significativo en los

	modelos de predicción para evaluar si esta inclusión mejora la precisión predictiva.			reservas de divisas como una variable predictiva adicional. El propósito de esta incorporación es evaluar si las reservas de divisas, al ser un factor crítico para la estabilidad económica y el control de la inflación, mejoran la precisión de los modelos ML en la predicción inflacionaria. Posteriormente, se utilizan métricas de evaluación como el Error Medio Absoluto (MAE), el Error Cuadrático Medio (MSE) y el Error Porcentual Absoluto Medio (MAPE) para medir la precisión predictiva de cada modelo. La inclusión de múltiples indicadores permite obtener una evaluación completa del rendimiento de los modelos, lo que garantiza una comparación justa entre los enfoques tradicionales y los basados en ML.	modelos de predicción de inflación.
Naghi A. A. et al. [84]	Evaluar los beneficios de predecir la inflación utilizando métodos de aprendizaje automático (ML) en comparación con métodos tradicionales.	El estudio emplea bases de datos macroeconómicas mensuales de varios países para evaluar la precisión y aplicabilidad de los modelos de aprendizaje automático (ML) en diferentes contextos económicos. Para Estados Unidos , se utiliza la base de datos FRED-MD versión de enero de 2016, que contiene 122 variables macroeconómicas mensuales. A estas variables se añaden cuatro componentes principales, cuatro rezagos de todas las variables y cuatro términos autorregresivos (AR), totalizando 508 predictores. El período cubierto abarca desde enero de 1960 hasta diciembre de 2015 (672 observaciones), con una parte fuera de muestra desde enero de 1990 hasta diciembre de 2015. El análisis se lleva a cabo	MÉTODOS INICIALES: Se incluye tanto enfoques tradicionales (como el UCSV y modelos de regresión penalizada) como métodos ML básicos, los cuales se describen a continuación: - Camino Aleatorio (RW). - Autorregresivo (AR). - Modelo de volatilidad estocástica de componentes no observados (UCSV). - LASSO, Red Elástica (EINet), Regresión Ridge (RR), y otros modelos de regresión como LASSO adaptable (adaLASSO) y Elastic Net adaptable (adaEINet). - Métodos basados en factores como: Regresión autorregresiva vectorial bayesiana (BVAR), agregación bootstrap (Bagging), regresión en subconjuntos combinados (CSR), método de promediado	La configuración experimental de los modelos de machine learning (ML) propuestos se centra en probar múltiples horizontes de predicción y en evaluar la precisión de cada método utilizando el error cuadrático medio (RMSE) y el error absoluto medio (MAE). Además de estas métricas tradicionales, el estudio incorpora intervalos de predicción y pruebas de cobertura para medir no solo la precisión puntual de los modelos, sino también la confiabilidad de sus estimaciones. Los experimentos se llevan a cabo en diversas muestras y períodos de tiempo, incluyendo subperíodos específicos como la pandemia de COVID-19, con el propósito de analizar el desempeño y la robustez de los modelos en condiciones de alta volatilidad.	Los resultados indican que los modelos de aprendizaje automático (ML), particularmente los basados en árboles y métodos de boosting, pueden superar a los métodos tradicionales en la predicción de la inflación. En particular, el Bosque aleatorio (RF) es efectivo en algunos contextos, pero métodos como el modelo de volatilidad estocástica (UCSV) y algunos modelos de boosting se destacan como más precisos durante períodos de alta volatilidad, como la pandemia de cronoavirus.

		<p>utilizando ventanas móviles, con las primeras 132 ventanas móviles conteniendo 359 observaciones cada una y las siguientes 180 ventanas móviles con 491 observaciones cada una.</p> <p>Para Canadá, se emplea un conjunto de datos que incluye 114 variables macroeconómicas registradas mensualmente desde enero de 1981 hasta febrero de 2022. Se utilizan cuatro factores de componentes principales, cuatro rezagos de todas las variables y cuatro términos autorregresivos (AR) de la variable dependiente de índice de precios al consumidor (CPI). El periodo fuera de muestra abarca desde marzo de 2011 hasta febrero de 2022, utilizando 132 ventanas móviles para las predicciones.</p> <p>En el caso del Reino Unido, se analiza un conjunto de datos con 110 variables macroeconómicas combinadas con los mismos predictores genéricos desde enero de 1998 hasta julio de 2021, combinadas con los mismos predictores genéricos de Canadá. La variable predicha es el índice CPI y el periodo fuera de muestra consta de 132 ventanas móviles desde agosto de 2010 hasta julio de 2021.</p>	<p>de modelos (JMA), factor, factor de tendencia (T.Factor), factor básico (B.Factor).</p> <ul style="list-style-type: none"> - Otros métodos como Bosque aleatorio (RF), media (Mean), media truncada (T.Mean), mediana (Median), combinaciones como RF/OLS y adaLASSO/RF. <p>NUEVOS MÉTODOS: Se consideraron más de 30 métodos de aprendizaje automático agrupados por grupos, los cuales se describen a continuación:</p> <p>1. Bosque Aleatorio (RF) y sus variaciones:</p> <ul style="list-style-type: none"> - Bosque lineal local (LLF). - Bosque aleatorio cuantílico. - Árboles extremadamente aleatorios (ERTs). - Bosque aleatorio orientado. - Bosque aleatorio macroeconómico (MacroRF). - Bosque aleatorio ajustado. <p>2. Métodos de Aumento de Gradiente (GBT):</p> <ul style="list-style-type: none"> - Árboles de aumento de gradiente extremo (XGBoost). - Máquinas potenciadas por gradiente ligero (LightGBM) con parámetros predeterminados. - Aprendices de árboles extremadamente aleatorios (LightGBM ERT). - Pérdida de cuantiles (Q LightGBM). - CatBoost. - Máquina de aumento de gradiente estándar (GBM) (versiones ajustada y no ajustada). <p>3. Modelos de Árboles de Regresión Aditiva Bayesiana (BART):</p> <ul style="list-style-type: none"> - BART estándar. - BART con una distribución previa en probabilidades de división (Dirichlet BART). 		
--	--	--	--	--	--

			<ul style="list-style-type: none"> - BART con reglas de división suaves (softBART). - BART con árboles modelo (MOTR-BART). - BART con errores heterocedásticos (HBART). - BART acelerado (XBART). - BART con promediado de modelos bayesianos (BART-BMA). <p>4. Regresión por Vectores de Soporte (SVR):</p> <ul style="list-style-type: none"> - SVR estándar (versiones ajustada y no ajustada). - SVR de mínimos cuadrados (SVR-LS). - SVR-LS con pérdida cuantílica (Q SVR-LS). - Máquinas de vectores relevantes (RVM). <p>5. Redes Neuronales (NNs):</p> <ul style="list-style-type: none"> - Redes Neuronales con función de activación ReLU y configuraciones de 3, 5 y 8 capas. <p>6. Métodos de Regresión Penalizada:</p> <ul style="list-style-type: none"> - LASSO. - Red elástica. - Regresión Ridge. - LASSO heterocedástico (RLASSO). - Post-RLASSO (aplicación de OLS a variables seleccionadas por RLASSO). - Red elástica ajustada. 		
Gupta S. y Kashyap S. [41]	Evaluar la eficacia de diferentes modelos de redes neuronales artificiales (ANN) en la predicción de la inflación, medida a través del índice de precios al consumidor (CPI), y comparar su rendimiento con	Se utilizó un conjunto de datos mensual del índice de precios al consumidor (CPI) de los países del G-7 (Estados Unidos, Reino Unido, Francia, Alemania, Italia, Japón y Canadá) desde enero de 1996 hasta febrero de 2013; obtenidos de la Oficina de Estadísticas Laborales de Estados Unidos (BLS), que está disponible en el sitio web oficial de la BLS (www.bls.gov/fls/intl_cons_umer_prices.xls). El conjunto de datos tiene 206 observaciones del IPC de los países mencionados.	- El estudio aplicó diferentes combinaciones de redes neuronales utilizando la función tangente hiperbólica como función de activación y el algoritmo de retropropagación con el método del gradiente descendente más pronunciado	La red neuronal artificial incluye una capa de entrada, una capa oculta y una de salida, utilizando la función de activación tangente hiperbólica para las capas ocultas y de salida. En el estudio, se probaron diferentes combinaciones respecto a la cantidad de neuronas en cada una de estas capas para los países del estudio. Los datos se dividieron en un 80% para entrenamiento, un 10% para pruebas y un 10% para validación. Se aplicó el algoritmo de retropropagación para	Los resultados indicaron que el modelo ANN ajustado proporcionó una buena precisión en la predicción de la inflación de los países del G-7. En particular, el modelo mostró una baja suma de errores al cuadrado (SSE), error cuadrático medio (RMSE) y error absoluto medio (MAE), demostrando su precisión en la predicción de la

	modelos tradicionales.			minimizar el error cuadrático.	inflación en los países del G-7. La predicción fuera de muestra también demostró que la inflación se reduciría marginalmente en el futuro cercano para los países del G-7. Los mejores resultados SSE, RMSE y MAE de los diferentes modelos de perceptrones multicapa de los países del G-7, fueron: EE. UU. (MLP- 3-8-1), Canadá (MLP- 8-1-1), Francia (MLP- 3-3-1), Alemania (MLP- 9-1-1), Italia (MLP- 10-5-1), Japón (MLP- 8-4-1) y Reino Unido (MLP- 4-7-1).
Simionescu M. [183]	Mejorar las predicciones utilizando modelos econométricos simples para ofrecer valores más realistas de la inflación.	Se emplearon datos trimestrales de Rumanía desde 2000 hasta 2014, que incluyen la tasa de inflación, el índice de precios al consumidor (CPI), el producto interno bruto (PIB) y la tasa de desempleo, ajustados estacionalmente con el método Tramo/Seats.	Se construyeron varios modelos econométricos para explicar la evolución del índice trimestral de precios, utilizando modelos de regresión múltiple y un modelo VAR (modelo vectorial-autorregresivo)	El modelo VAR(2) demostró ser el más adecuado según los criterios de selección de longitud de rezago. Este modelo analiza la relación causal entre la tasa de inflación y la tasa de desempleo, así como la descomposición de la varianza para evaluar el impacto de las variaciones en estas variables.	Los resultados del modelo VAR indican una relación recíproca entre inflación y desempleo en Rumanía, con la volatilidad de la inflación explicada sin descender por debajo del 88% por su propia evolución y la del desempleo en más del 99% por su variabilidad interna. El PIB impacta negativamente la inflación, mientras que un aumento previo en la inflación eleva su valor en el presente. Las predicciones basadas en este modelo superaron los objetivos del Banco Nacional de Rumanía para 2015-2016, sugiriendo que estos modelos econométricos pueden ofrecer metas de inflación más realistas.

Apéndice F. Factores predictores que influyen en la tasa de desempleo

N°	Estudio/Autor(es)	Factores predictores que influyen en la tasa de desempleo
1	Explaining Unemployment Rates with Symbolic Regression Philip Truscott y Michael Kornis	<ul style="list-style-type: none"> - Cambio en la inflación - Duracion del beneficio - Ratio de reemplazo - Gastos en políticas activas del mercado laboral - Cobertura sindical - Coordinación sindical - Coordinación de empleadores
2	Prediction Model of the Unemployment Rate for Nanyang in Henan Province based on BP Neural Network Yiyuan Cheng, Tao Hai, Yangbing Zheng	<ul style="list-style-type: none"> - PIB (producto interno bruto) - Valor agregado de la industria primaria - Valor agregado de la industria secundaria - Valor agregado de la industria terciaria - IPC (índice de precios al consumidor) - Inversión en activos fijos - Las importaciones y exportaciones totales - Las ventas minoristas totales de bienes de consumo - Gastos financieros - Número de población urbana - Renta disponible de los residentes urbanos - Saldo de los depósitos de ahorro de los residentes urbanos y rurales - El valor agregado de toda la industria de la ciudad
3	Prediction of the unemployment rate in Malaysia Suraya Fadilah Ramli, Muhammad Firdaus, Hazmi Uzair, Muhammad Khairi y Amirul Zharif	<ul style="list-style-type: none"> - PIB (producto interno bruto) - Número de la población - Tasa de inflación <p data-bbox="813 1052 1555 1104">Nota: Otro factor es el tipo de cambio según Asif, 2013 (pero no se lo consideró en este estudio)</p>
4	Improving unemployment rate forecasts at regional level in Romania using Google Trends Simionescu Mihaela	<ul style="list-style-type: none"> - Mercado laboral rumano <p data-bbox="813 1142 1555 1163">Desde el NIS, se obtuvieron:</p> <ul style="list-style-type: none"> - Tasa de desempleo - PIB real - Número de emigrantes
5	Workopolis or The Pirate Bay: what does Google Trends say about the unemployment rate? Maryam Dilmaghani	<p data-bbox="813 1268 1555 1289">De Google Trends:</p> <p data-bbox="813 1289 1555 1310">Datos sobre la intensidad de las actividades de ocio en línea, como:</p> <ul style="list-style-type: none"> - Items de ocio online. - Items de búsqueda de empleo en línea. - Índice de búsqueda de empleo de Google (GJSI) <p data-bbox="813 1404 1555 1425">De CANSIM:</p> <ul style="list-style-type: none"> - Tasa de desempleo no ajustada
6	Predicting the Unemployment Rate Using Social Media Analysis Pum-Mo Ryu	<ul style="list-style-type: none"> - Tasa de desempleo (Statistics Korea) - Índice de Google GI (Google Trends) - Artículos de noticias, blogs y tweets (Redes sociales)
7	The predictive power of Google searches in forecasting US unemployment Francesco D'Amuri, Juri Marcucci	<ul style="list-style-type: none"> - Tasa de desempleo mensual ajustada estacionalmente (Oficina de Estadísticas Laborales (BLS)) - IC semanal ajustado estacionalmente (Departamento de Trabajo de EE. UU.) - Las expectativas de empleo para los sectores de manufactura y no manufactura (Informe de Negocios del Institute for Supply Management (ISM)) - Encuesta de confianza del Consumidor de EE. UU. (Conference Board) - índice de incertidumbre de la política económica
8	Prediction of employment and unemployment rates from Twitter daily rhythms in the US Eszter Bokányi, Zoltán Lábszki and Gábor Vattay	<ul style="list-style-type: none"> - 63 millones de tweets de los Estados Unidos

9	Google's MIDAS Touch: Predicting UK Unemployment with Internet Search Data Paúl Smith	GoogJSA GoogRed GRI RoJPP RoJTB RoJVC RoJSA PMIEM ConExp BoESR BoEMN F1 F2 Nota: El significado de estas variables se explican en el apéndice A.3 del artículo.
10	A multi-granularity combined prediction model based on fuzzy trend forecasting and particles warm techniques Weihui Deng, Guoyin Wang, Xuerui Zhang, JiXu, Guangdi Li	Índices bursátiles y series de tiempo de desempleo civil
11	Forecasting Youth Unemployment in Korea with Web Search Queries Chi-Myung Kwon and Jae Un Jung	Tasa de desempleo juvenil (OCDE) Palabras clave para consultas web asociadas con la tasa de desempleo juvenil de Corea Nota: Las palabras claves se indican en el apartado 4.1 Recopilación y preprocesamiento de información de consultas web
12	Nowcasting Unemployment Rates with Google Searches Evidence from the Visegrad Group Countries Jaroslav Pavlicek, Ladislav Kristoufek	Datos mensuales de desempleo Valores actuales y rezagados de las búsquedas de Google (en idioma checo, polaco y eslovaco): "gumtree", "práce", "prace", "práca" y "praca"
13	Forecasting Spanish Unemployment Using Near Neighbour and Neural Net Techniques Elena Olmedo	Tasas de desempleo mensuales ajustadas estacionalmente
14	An ontology-based Web mining method for unemployment rate prediction Ziang Li a, Wei Xua, Likuan Zhang, Raymond Y.K. Lau	- Número de solicitudes iniciales de desempleo (UIC) - 423 consultas de motores de búsqueda relevantes. Algunas características relevantes que menciona el estudio son: Michigan unemployment, Coupons, Florida unemployment, Personal finance, Layoff, Family budget, Hospital pharmacist, Economy, Alaska unemployment y Economy current
15	Forecasting unemployment with internet search data: Does it help to improve predictions when job destruction is skyrocketing? María Rosalía Vicente, Ana J. López-Menéndez and Rigoberto Pérez	Variables explicativas tanto del lado de la demanda como de la oferta del mercado laboral. Del lado de la demanda: análisis el Indicador de Confianza en el Empleo (ICE) Del lado de la oferta: búsqueda en línea ("oferta de trabajo" y "oferta de empleo")
16	Unemployment and GDP Martina Miskolczi, Jitka Langhamrová and Tomáš Fiala	- PIB - Consumo e inversiones a precios constantes y ajustados estacionalmente - Empleo y desempleo de la Encuesta por muestreo de la fuerza laboral organizada trimestralmente (LFSS) - Tasa de inflación como un aumento en el IPC anual promedio que indica un cambio porcentual en el promedio de los últimos 12 meses sobre el promedio de los 12 meses anteriores - Salarios como el salario bruto mensual medio.
17	Data mining for unemployment rate prediction using search engine query data Wei Xu, Ziang Li, Cheng Cheng and Tingting Zheng	- Datos de consulta del motor de búsqueda "Local/Jobs" "Society/Social Services/Welfare & Unemployment"

		- Tasa de desempleo de datos (US Department of Labor)
18	Nowcasting unemployment rate and new car sales in south-western Europe with Google Trends Nuno Barreira, Pedro Godinho and Paulo Melo	Para las búsquedas de Google, se asumió que las búsquedas más relevantes que se referirían a las prestaciones por desempleo y desempleo: subsidio desempleo and desempleo for Portugal ; subsidio de desempleo, desempleo and prestacion desempleo for Spain ; indemnités chômage, allocations chômage, allocations de chômage, chômage for France ; and disoccupazione ordinaria, INPS1 disoccupazione, disoccupazione for Italy . - Datos desestacionalizados sobre las tasas de desempleo mensuales
19	Forecasting the unemployment rate over districts with the use of distinct methods* Marcin Wozniak	- Tasa de desempleo (urate), - Número de desempleados (u), - Número de vacantes (v), - Entrada al desempleo registrado (inf), - Salida del desempleo al mercado laboral (salida), - Estrechez del mercado laboral (v / u).
20	Nowcasting Unemployment Rates with Smartphone GPS Data Daisuke Moriwaki	Ubicación geográfica de los usuarios OBTENIDA mediante GPS. Los datos constan de cuatro columnas: id hash, latitud, longitud y marca de tiempo.