

UNIVERSIDAD NACIONAL HERMILIO VALDIZÁN
FACULTAD DE ECONOMÍA
ESCUELA PROFESIONAL DE ECONOMÍA
CARRERA PROFESIONAL DE ECONOMÍA



**NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL
ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980
– 2021**

LÍNEA DE INVESTIGACIÓN: ECONOMÍA Y NEGOCIOS

**SUBLÍNEA DE INVESTIGACIÓN: CIENCIAS ECONÓMICAS Y
SOCIALES**

TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE ECONOMISTA

TESISTAS:

**ALVAREZ FLORES JHON HARRINSON
ENRIQUEZ MONTES CRHISTIAN JHON
TINEO CRUZ RAFAELA CAROLINA**

ASESOR:

ALVARADO CHAVEZ CLAYTON

HUÁNUCO – PERÚ

2024

DEDICATORIA

Manifestamos nuestro agradecimiento a Dios y a nuestros amados progenitores por su constante respaldo durante nuestra experiencia universitaria. Esta investigación es un homenaje a su legado y eterno respaldo. Son nuestros pilares y nuestra mayor inspiración.

AGRADECIMIENTO

Anhelamos comunicar nuestro más profundo agradecimiento a las figuras paternas y docentes, aquellos que siempre nos han brindado un soporte absoluto en el cumplimiento de nuestros objetivos personales y académicos. Su constante respaldo ha sido fundamental en nuestro camino hacia el éxito.

RESUMEN

La investigación se centra en evaluar la efectividad del modelo de redes neuronales en el análisis del comportamiento y predicción del Producto Bruto Interno (PBI) de Perú desde 1980 hasta 2021. Se fundamenta en la capacidad de las redes neuronales artificiales para aprender automáticamente y capturar relaciones complejas entre variables, lo que las hace útiles para la predicción económica.

El problema de investigación está centrado en el análisis del comportamiento y predicción del PBI de Perú, el cual se desarrolla bajo métodos tradicionalmente aceptados por las ciencias económicas; sin embargo, con el ingreso a la era del conocimiento y de la inteligencia artificial se presentan nuevas alternativas para determinar con mayor rigurosidad científica el comportamiento histórico y la estimación futura de esta variable macroeconómica. Los objetivos están relacionados con la estimación del coeficiente de determinación (R^2) para evaluar la efectividad del modelo de redes neuronales para el periodo de estudio. En la misma línea, se plantea las hipótesis que sugieren altos niveles de efectividad en el análisis del comportamiento y predicción del PBI de Perú.

Los hallazgos conseguidos sugieren que el modelo de redes neuronales es altamente eficiente para los fines que buscamos en la investigación, lo que se corrobora con un R^2 de 0.9879. Así mismo, se observa alta eficiencia en el análisis del comportamiento del PBI hasta 2010, con un R^2 de 0.896, y una eficiencia ligeramente menor en la predicción del PBI de 2011 a 2021, con un R^2 de 0.7662.

PALABRAS CLAVES: Modelo de redes neuronales, efectividad de modelo, series de tiempo

ABSTRACT

The research focuses on evaluating the effectiveness of the neural network model in the analysis of the behavior and prediction of the Gross Domestic Product (GDP) of Peru from 1980 to 2021. It is based on the ability of artificial neural networks to automatically learn and capture relationships complex between variables, which makes them useful for economic prediction.

The research problem is focused on the analysis of the behavior and prediction of Peru's GDP, which is developed under methods traditionally accepted by economic sciences; However, with the entry into the era of knowledge and artificial intelligence, new alternatives are presented to determine with greater scientific rigor the historical behavior and future estimation of this macroeconomic variable. The objectives are related to the estimation of the determination coefficient (R^2) to evaluate the effectiveness of the neural network model for the study period. Along the same lines, hypotheses are proposed that suggest high levels of effectiveness in the analysis of the behavior and prediction of Peru's GDP.

The findings obtained suggest that the neural network model is highly efficient for the purposes we seek in the research, which is corroborated with an R^2 of 0.9879. Likewise, high efficiency is observed in the analysis of the behavior of GDP until 2010, with an R^2 of 0.9896, and a slightly lower efficiency in the prediction of GDP from 2011 to 2021, with an R^2 of 0.76620.

KEYWORDS: Neural network model, model effectiveness, time series

ÍNDICE

DEDICATORIA	ii
AGRADECIMIENTO	iii
RESUMEN	iv
ABSTRACT.....	v
INTRODUCCION	x
CAPITULO I. ASPECTOS BÁSICOS DEL PROBLEMA DE INVESTIGACIÓN ...	11
1.1. Fundamentación del problema de investigación	11
1.2. Formulación del problema de investigación	12
1.2.1. Problema General	12
1.2.2. Problemas Específicos	12
1.3. Formulación de objetivos	12
1.3.1. Objetivo General.....	12
1.3.2. Objetivos Específicos	12
1.4. Justificación e importancia de la investigación.....	13
1.5. Viabilidad de la investigación	13
CAPITULO II. MARCO TEORICO	14
2.1. Antecedentes de la Investigación	14
2.2. Base teórica	15
2.3. Bases conceptuales o definición de términos básicos	18
CAPITULO III. SISTEMA DE HIPOTESIS	20
3.1. Formulación de hipótesis	20
3.1.1. Hipótesis General.....	20
3.1.2. Hipótesis Especifica.....	20
3.2. Variables y operacionalización de variables	20
3.3. Definición teórica de variables.....	22
CAPITULO IV. METODOLOGÍA	23

4.1.	Ámbito o lugar de ejecución	23
4.2.	Tipo y Nivel de investigación	23
4.3.	Población y muestra	23
4.3.1.	Descripción de la población.....	23
4.3.2.	Muestra y método de muestro.....	24
4.3.3.	Criterios de inclusión y exclusión.....	24
4.4.	Diseño de investigación	24
4.5.	Métodos, técnicas e instrumentos	25
4.5.1.	Método	25
4.5.2.	Técnicas	25
4.5.3.	Instrumentos.....	26
4.6.	Técnicas de procesamiento y análisis de datos	28
4.6.1.	Datos a registrar	28
4.6.2.	Procedimiento	34
4.6.3.	Plan de tabulación y análisis de datos estadísticos	49
CAPITULO V. RESULTADOS Y DISCUSION.....		50
5.1.	Análisis descriptivo.....	50
5.2.	Análisis inferencial y/o contrastación hipótesis.....	53
5.3.	Discusión de resultados.....	69
CONCLUSIONES		72
RECOMENDACIONES.....		73
REFERENCIAS BIBLIOGRÁFICAS		74
ANEXOS		76

INDICE DE TABLA

Tabla 1. Variable.....	20
Tabla 2. Operacionalización de variables	21
Tabla 3. Validación del instrumento	26
Tabla 4. Base de datos	28
Tabla 5. Principales Estadísticas Descriptivas.....	51
Tabla 6. Coeficiente de determinación	63
Tabla 7. Coeficiente de determinación	64
Tabla 8. Coeficiente de determinación	66

INDICE DE GRAFICOS

Gráfico 1. PBI trimestral de Perú 1980 - 2021	50
Gráfico 2. Histograma del PBI de Perú	51
Gráfico 3. Curva de aprendizaje (10 épocas).....	53
Gráfico 4. Curva de aprendizaje (20 épocas).....	53
Gráfico 5. Curva de aprendizaje (30 épocas).....	54
Gráfico 6. Curva de aprendizaje (40 épocas).....	54
Gráfico 7. Curva de aprendizaje	56
Gráfico 8. Curva de aprendizaje	56
Gráfico 9. Datos reales y estimados (10 épocas)	58
Gráfico 10. Datos reales y estimados (20 épocas)	58
Gráfico 11. Datos reales y estimados (30 épocas)	59
Gráfico 12. Datos reales y estimados (40 épocas)	59
Gráfico 13. Diagrama de dispersión y línea de tendencia	62
Gráfico 14. Datos reales y estimados (datos conocidos)	63
Gráfico 15. Diagrama de dispersión datos reales y estimados (datos conocidos)	64
Gráfico 16. Datos reales y estimados (datos no conocidos)	65
Gráfico 17. Diagrama de dispersión datos reales y estimados (datos no conocidos)	65

INTRODUCCION

El modelo de redes neuronales artificiales representa una innovación significativa en el análisis y procesamiento de datos. Este estudio se enfoca en evaluar la efectividad del modelo de redes neuronales en el análisis y predicción del Producto Bruto Interno (PBI) de Perú desde 1980 hasta 2021.

El problema de investigación radica en la necesidad de mejorar la precisión en el análisis del comportamiento y la predicción del PBI. Tradicionalmente, este análisis se ha realizado mediante métodos econométricos y estadísticos, que, aunque efectivos, pueden tener limitaciones en cuanto a la captura de relaciones complejas entre variables. La inteligencia artificial, y específicamente las redes neuronales, ofrece una alternativa prometedora para abordar estas limitaciones y proporcionar un análisis más preciso y detallado.

Los objetivos de esta investigación son evaluar la efectividad de las redes neuronales en la predicción del PBI de Perú, determinando su coeficiente de determinación (R^2) para los periodos estudiados. Se plantean hipótesis que sugieren altos niveles de efectividad en el análisis del comportamiento y predicción del PBI de Perú. La metodología empleada incluye un diseño de investigación no experimental, con técnicas y métodos específicos para la validación del modelo propuesto.

Los resultados obtenidos muestran que el modelo de redes neuronales es altamente eficiente en la predicción del PBI, con un coeficiente de determinación R^2 de 0.9879 para el periodo completo. Se observa una alta eficiencia en el análisis del comportamiento del PBI hasta 2010, con un R^2 de 0.9896, y una eficiencia ligeramente menor en la predicción del PBI de 2011 a 2021, con un R^2 de 0.76620. Estos hallazgos corroboran la efectividad de las redes neuronales en el análisis y predicción económica.

Las conclusiones del estudio resaltan la validez del modelo de redes neuronales como una metodología eficaz para el análisis económico, recomendando su aplicación en otros contextos y periodos para continuar mejorando la precisión de las predicciones económicas. Además, se sugiere una mayor integración de técnicas de inteligencia artificial en el análisis macroeconómico para aprovechar al máximo las capacidades de estas tecnologías avanzadas.

CAPITULO I. ASPECTOS BÁSICOS DEL PROBLEMA DE INVESTIGACIÓN

2.1. Fundamentación del problema de investigación

El modelo de redes neuronales artificiales representa una importante innovación en el análisis, como también en el procesamiento de datos, debido a que, a diferencia de los modelos convencionales, estadísticos y econométricos, las redes neuronales artificiales se tienen sus bases en el aprendizaje automático y requieren poca o ninguna ayuda para analizar los datos.

Entre las bondades del modelo de redes neuronales frente a los modelos econométricos, se encuentra que el análisis no solo es de inferencia causal entre variables, sino también aprender automáticamente el comportamiento de una variable y predecir su comportamiento futuro. Además, las redes neuronales pueden analizar enormes cantidades de datos de manera más eficiente y encontrar patrones que podrían pasar desapercibidos en los modelos econométricos.

Las redes neuronales exhiben una notable versatilidad al modelar conexiones que no siguen una estructura lineal o paramétrica entre variables. Esta característica les permite representar relaciones de mayor complejidad y, en consecuencia, mejorar la exactitud en la realización de predicciones. Asimismo, poseen la capacidad de adaptarse a cambios en su entorno y de ajustar sus parámetros con el fin de lograr una mejor adecuación al modelo.

La aplicación de redes neuronales en el análisis y la predicción de variables macroeconómicas se presenta como una herramienta sumamente beneficiosa para respaldar la toma de decisiones en asuntos económicos. Esto se debe a su habilidad para aprender de manera automática y capturar conexiones complejas entre variables, lo que les permite realizar pronósticos más precisos y ajustarse a cambios en el entorno con facilidad.

La implementación del modelo de redes neuronales en el análisis del Producto Bruto Interno (PBI) del Perú se perfila como una herramienta fundamental para comprender las tendencias económicas del país de manera más efectiva. Esta tecnología permitirá una mayor precisión en la interpretación de los datos relacionados con el PBI, lo que facilitará la identificación de patrones y tendencias económicas clave. Además, la capacidad de adaptación de las redes neuronales les permitirá mejorar continuamente su capacidad predictiva, lo que contribuirá significativamente a una comprensión más profunda y

precisa del panorama económico peruano. La implementación de estos modelos va a permitir a los economistas y analistas obtener predicciones más precisas y confiables respecto a la evolución del PBI.

El PBI es una medida clave de la actividad económica de un país, y su análisis es fundamental para entender el desempeño económico y las perspectivas de crecimiento. Las redes neuronales es un modelo que se utiliza para analizar grandes conjuntos de datos y encontrar patrones y tendencias.

Los modelos de redes neuronales también pueden ayudar a identificar que afecta el crecimiento del PBI. Por ejemplo, pueden analizar como el cambio en políticas gubernamentales afecta en el crecimiento económico, las fluctuaciones en los precios de los productos básicos, las tendencias en el mercado laboral y otros factores que pueden influir en el crecimiento económico. Sin embargo, para la presente investigación solo se analizó el comportamiento del PBI de Perú.

2.2. Formulación del problema de investigación

4.3.1. Problema General

PG: ¿En qué medida la aplicación del modelo de redes neuronales resulta efectivo con el análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021?

4.3.2. Problemas Específicos

PE1: ¿De qué forma la aplicación del modelo de redes neuronales resulta efectivo con el análisis del comportamiento del PBI de Perú: 1980 - 2010?

PE2: ¿De qué forma la aplicación del modelo de redes neuronales resulta efectivo con el análisis de la predicción del PBI de Perú 2011 - 2021?

1.3. Formulación de objetivos

1.3.1. Objetivo General

OG: Evaluar el nivel de efectividad del modelo de redes neuronales con relación al análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021.

1.3.2. Objetivos Específicos

OE1: Estimar el R^2 para evaluar el nivel de efectividad del modelo de redes neuronales con relación al análisis del comportamiento del PBI de Perú: 1980 – 2010.

OE2: Estimar el R^2 para evaluar el nivel de efectividad del modelo de redes neuronales en el análisis predicciones el PBI del Perú: 2011 – 2021.

1.4. Justificación e importancia de la investigación

La validación de un modelo de estimación alternativo en el análisis del comportamiento y predicción de variables económicas es de gran importancia en el ámbito de la economía y la toma de decisiones. Los modelos habituales, como los modelos econométricos y estadísticos, pueden estar sujetos a sesgos y limitaciones que afectan la objetividad de los resultados.

Por lo tanto, contar con un modelo de estimación alternativo, como el Modelo de Redes Neuronales, que pueda ser más objetivo a la hora del análisis del comportamiento y predicción de variables económicas, se convierte en una herramienta valiosa en la toma de decisiones. Esto se debe a que la objetividad en el análisis y la predicción de variables económicas es fundamental para la elaboración de políticas públicas y privadas eficientes. Además, los modelos de estimación alternativos, como las redes neuronales, tienen la capacidad de procesar grandes cantidades de datos y encontrar patrones y relaciones complejas que podrían pasar desapercibidos en los modelos convencionales. Esto puede proporcionar una visión más completa y precisa de las tendencias económicas, lo que a su vez puede mejorar la eficacia de las políticas públicas y las decisiones empresariales.

1.5. Viabilidad de la investigación

La investigación sobre el modelo de redes neuronales para analizar y predecir el PBI de Perú (1980-2021) es viable y relevante, dada la aplicabilidad de la inteligencia artificial (modelo de redes neuronales) en la economía. Con objetivos claros y una metodología descriptiva no experimental, se evaluará la efectividad del modelo mediante el R^2 . Se cuenta con los recursos necesarios, tanto financieros como técnicos y humanos. Los aspectos éticos y la seguridad de datos están contemplados. El proyecto tiene un alto potencial de éxito y originalidad, contribuyendo significativamente al análisis económico.

CAPITULO II. MARCO TEORICO

2.3. Antecedentes de la Investigación

A continuación, algunos trabajos con relación a los conocimientos sobre la aplicación del Modelo de Redes Neuronales en variables económicas de estudio a nivel internacional.

(Arrieta, Torres, & Velásquez, 2009) “Al igual que los modelos econométricos, las redes neuronales logran capturar adecuadamente el comportamiento de los datos dentro del conjunto de entrenamiento (in sample). No obstante, en cuanto a las predicciones de precios fuera de la muestra de entrenamiento, las redes neuronales muestran un avance significativo en comparación con el desempeño de los modelos econométricos habituales. Las redes neuronales son capaces de representar mucho mejor la dinámica real de la serie de tiempo, además de mejorar considerablemente el ajuste y precisión de las predicciones en datos nuevos no vistos durante el entrenamiento.”

(Byrd, 1998) “Si bien este trabajo ha sentado las bases para el desarrollo de nuevas aplicaciones, también ha generado una gran incertidumbre debido a la falta de indicadores analíticos adecuados para evaluar de manera rigurosa el desempeño de estas técnicas. Esta carencia de métricas confiables para medir su efectividad ha motivado, a su vez, un mayor interés por profundizar la investigación sobre estas técnicas, con el fin de comprenderlas mejor y establecer criterios sólidos para valorar su resultado.”

(Ceular & Caridad y Ocerín, 2001) “Los resultados muestran que la red neuronal empleada tiene un mayor poder predictivo en comparación con el modelo hedónico tradicional. Una de las principales ventajas de los sistemas neuronales artificiales es su flexibilidad para adaptarse a cambios en el entorno, sin necesidad de reprogramarlos completamente. Basta con realizar un reajuste de los pesos de las conexiones para que puedan amoldarse a las nuevas condiciones. Además, estas redes poseen la capacidad de extraer las características más relevantes a partir de grandes volúmenes de datos, filtrando la información redundante y centrándose en los patrones fundamentales.”

(Arturo, Hernan, & Medina, 2009) “Las redes neuronales artificiales presentan una ventaja práctica sobre los modelos estadísticos tradicionales cuando se trata de aplicaciones en el mercado bursátil. Esto se debe a que las redes neuronales no dependen de supuestos teóricos en los que se basan las técnicas estadísticas convencionales, tales como normalidad, homocedasticidad e independencia de los datos. Al no requerir que se cumplan estos supuestos, las redes neuronales pueden manejar patrones más complejos y

no lineales presentes en los mercados financieros, lo que las hace más flexibles y adaptables a este tipo de entornos dinámicos.”

(Saenz, 2009) “El mercado de divisas se caracteriza por un alto nivel de complejidad debido a factores económicos externos y al elevado grado de especulación por parte de los agentes que intervienen en él. Las redes neuronales artificiales representan una opción viable para pronosticar las tasas de cambio de monedas debido a estas características. A diferencia de métodos estadísticos como los modelos ARIMA, que presuponen que la serie temporal sigue una distribución de probabilidad particular, las redes neuronales no hacen suposiciones previas sobre el comportamiento de las series temporales analizadas. Esta flexibilidad las convierte en una opción más adecuada para abordar la dinámica compleja e impredecible del mercado cambiario.”

(Saenz, 2009) “Los resultados muestran que las redes neuronales tienen una capacidad predictiva significativa y estable durante un intervalo de tiempo aún por determinar con precisión. Esto implica que las redes neuronales, una vez entrenadas adecuadamente, pueden ser una fuente valiosa de información al momento de tomar decisiones de inversión en empresas tanto de economías locales como extranjeras. Gracias a que las entradas se retrasaron 4 meses para la economía estadounidense y 15 meses para la mexicana, estas redes permiten realizar proyecciones con bastante anticipación, lo cual resulta conveniente para ciertas estrategias de inversión que requieren de previsiones a mediano y largo plazo.”

(Saenz, 2009) “El uso de redes neuronales artificiales para modelar el PIB en Colombia reveló que esta variable presenta relaciones no lineales en su proceso generador de datos, las cuales las redes neuronales lograron capturar con éxito. Esto se demostró al superar ampliamente el desempeño del modelo lineal ARIMA. No obstante, debido a que las redes neuronales se consideran "cajas negras", no es posible identificar directamente la fuente de las no linealidades presentes en el PIB, como las mencionadas en la sección dos de ese trabajo. Para evaluar si la incorporación de la política monetaria mejora la explicación de los comportamientos no lineales, se incluyó una aproximación de esta a través de la tasa de interés de los CDT a 90 días en una red neuronal. Los resultados mostraron que este modelo ampliado logró mejorar los pronósticos al menos dos periodos hacia adelante, demostrando que esta variable es relevante para el comportamiento del PIB.”

2.4. Base teórica

Teoría economía

En la teoría macroeconómica se concibe del Producto Bruto Interno (PBI) que vendría a ser el indicador más usado para explicar la economía, es considerado el indicador más importante por su capacidad de representar y explicar el comportamiento de una economía.

El PBI puede ser representado a partir de tres métodos:

Método de gasto.

Método del ingreso.

Método del valor agregado.

Método del gasto

Desde el punto de vista del Gasto o destino de la producción, el PBI mide el valor de las diferentes utilizaciones finales de la producción en la Economía, restándose el valor de las importaciones de los bienes y servicios (producción no generada en el territorio interior).

$$PBI = C + I + G + XN$$

$$PBI = (C, I, G, XN)$$

Donde:

C: consumo

I: inversiones

G: gasto

XN: exportaciones netas

Método del Ingreso

El PIB es la suma de los ingresos por salarios, las ganancias corporativas y los impuestos menos los subsidios. La diferencia entre el valor de la producción de la empresa y el valor del producto intermedio tiene uno de tres propósitos: ingreso del trabajo, ganancias de la empresa o impuestos indirectos del gobierno como el impuesto al valor agregado.

$$PBI = RA + EBE + impuestos - subvenciones$$

Donde:

RA: remuneración de asalariados

EBE: excedente bruto de explotación

Método del Valor Agregado

Para calcular el PIB utilizando el método del valor agregado, se debe añadir el valor agregado bruto originado por la producción de bienes y servicios.

$$PBI = VAB + impuestos - subvenciones$$

Donde:

VAB: valor agregado bruto

Teoría del crecimiento económico

En la investigación sobre el crecimiento económico, la productividad es uno de los elementos fundamentales para alcanzar tasas y niveles de crecimiento significativos. A pesar de que ni siquiera es el factor más relevante en los modelos de crecimiento para los críticos de la teoría neoclásica, parece ser una constante en todos los análisis realizados hasta el momento, y no se puede evitar investigar este fenómeno. En consecuencia, puede considerarse como una variable fundamental del crecimiento económico.

Teoría de la Inteligencia artificial

El área de la investigación que se dedica a resolver este problema se denomina inteligencia artificial. Se trata de un ámbito multidisciplinario que, a través de estudios como la computación, la matemática, la lógica y la filosofía, investiga la creación y diseño de sistemas capaces de solucionar problemas cotidianos de forma independiente, utilizando como paradigma la inteligencia humana.

En este contexto, podemos hallar algoritmos de Machine Learning (ML) en este contexto. Se solucionan situaciones por sí solo mediante un análisis de datos y cuantos más datos tengan mejores resultados, además, se emplean algoritmos que diseñan otros datos de acuerdo con las necesidades, una de estas herramientas de ML son los modelos de redes neuronales artificiales. Estas técnicas posibilitan al estudiante reconocer patrones, obtener conocimiento, obtener información y realizar predicciones.

Clasificación de redes neuronales artificiales:

Un perceptrón multicapa evoluciona sobre un perceptrón simple, que contiene capas de neuronas ocultas, lo que permite la representación de funciones no lineales. Un sensor multicapa compuesto por una capa de entrada, una capa de salida y n capas ocultas en el medio. Se caracteriza por salidas inconexas pero conectadas, como salidas inconexas, pero conectadas. Por ejemplo, la salida de una neurona es la entrada de la siguiente neurona.

Red neuronal convolucional; pueden tener decenas de miles o cientos de capas, y cada capa aprende a detectar una característica diferente de una figura. Los filtros se aplican a las figuras de entrenamiento en diferentes resoluciones, y la salida de cada convolución se usa como entrada para la siguiente capa. Los filtros pueden comenzar con características muy simples, como la forma o los bordes, y gradualmente volverse más complejos hasta convertirse en las únicas características definitorias de un objeto.

Redes de base radial; Se trata de una red neuronal artificial que calcula la salida de una función en función de la distancia a un punto llamado centro. De la misma forma que los perceptrones multicapa, actúan como aproximadores universales.

Red Neuronal Recurrente; Las redes neuronales recurrentes son redes que son capaces de influir en sí mismas a través de recurrencias, por ejemplo, mediante la inclusión de la salida de la red en los pasos siguientes de cálculo.

Estructura de una red neuronal artificial recurrente

Existen, por lo general, tres conjuntos de parámetros para una red neuronal recurrente: la entrada a los pesos ocultos (W), los pesos ocultos (U), y los pesos ocultos a etiquetar (V). Observe que todos los W son compartidos, así como toda la U y todos los V son compartidos. La propiedad de compartir el peso permite que la red sea adecuada para entradas de tamaño variable.

2.5. Bases conceptuales o definición de términos básicos

Antes de abordar una definición precisa de un modelo de red neuronal, es esencial comprender qué es la inteligencia artificial, de la cual deriva este modelo. La inteligencia artificial se define como un campo de estudio dentro de la ciencia que tiene como objetivo replicar o imitar las capacidades humanas a través de sistemas o algoritmos computacionales. Dentro de este campo, el Machine Learning (ML) se posiciona como un subconjunto, donde se entrena a una máquina para aprender. En este contexto, un modelo de Machine Learning se concibe como una representación matemática que describe la relación entre diferentes variables. El método de Machine Learning es una técnica de análisis de datos que posibilita la automatización de la creación y empleo de modelos estadísticos, los cuales pueden adquirir patrones y realizar predicciones o tomar decisiones sin ser explícitamente programados para llevar a cabo tareas particulares. La presente técnica habilita a una computadora para adquirir conocimientos a partir de la información proporcionada, identificar patrones y tomar decisiones mediante una intervención humana.

Inteligencia artificial

Una definición brindada por (McCarthy, 2007) de la inteligencia artificial (IA) “La inteligencia artificial es el campo que se dedica al desarrollo de máquinas inteligentes, como programas de computadora avanzados. Aunque se vincula con el estudio de cómo las computadoras pueden comprender la inteligencia humana, la IA no está restringida a métodos que imiten directamente procesos biológicos.”

Machine Learning

La definición brindada por (IBM, 2018) sobre Machine learning El aprendizaje automático se considera una disciplina dentro de la inteligencia artificial que capacita a un sistema para aprender de los datos en lugar de depender únicamente de instrucciones programadas de forma explícita. Aunque este proceso no es sencillo, a medida que el algoritmo procesa conjuntos de datos de entrenamiento, puede generar modelos más precisos basados en la información obtenida.”

Redes Neuronales Artificiales

La definición brindada por (IBM, 2021) sobre Redes Neuronales Artificiales “Este es un modelo simplificado que replica el proceso de procesamiento de información del cerebro humano: funciona mediante la conexión simultánea de múltiples unidades de procesamiento, que son representaciones abstractas de las neuronas.”

Efectividad en los modelos de redes neuronales

Para medir la efectividad de un modelo de redes neuronales que se utiliza para predecir el Producto Bruto Interno (PBI), se puede usar diferentes métricas, pero una forma bastante habitual de hacerlo es usando el “r cuadrado”, con el cual se puede calcular el coeficiente de determinación (R^2) como una medida de cuánto se parecen los valores predichos a los valores observados. Se puede seguir este enfoque basado en la regresión lineal para calcular R^2 .

En el contexto de las redes neuronales, se generarían predicciones del modelo para un conjunto de datos, y posteriormente se compararían con los valores obtenidos. A continuación, se analizarían las sumas de cuadrados residual y total como parte del proceso para determinar el coeficiente de determinación R^2 .

En el caso de que el coeficiente de determinación (R^2) sea del 0%, se indica que el modelo no describe ninguna parte de la variabilidad de los datos de respuesta en relación con su media. Por otra parte, un R^2 del 100% indica que el modelo describe toda la variabilidad de los datos de respuesta en relación con su media.

Producto Bruto Interno (PBI)

La definición proporcionada por el (Ministerio de Economía y Finanzas, 2022) de Producto Bruto Interno se refiere al total de gastos realizados en la compra de bienes o servicios finales producidos dentro de una economía. Se excluyen las compras de bienes o servicios intermedios, así como los bienes o servicios importados

CAPITULO III. SISTEMA DE HIPOTESIS

3.1. Formulación de hipótesis

3.1.1. Hipótesis General

HG: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021.

3.1.2. Hipótesis Especifica

HE1: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento de los datos del PBI: 1980 - 2010.

HE2: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis de la predicción de los datos del PBI de Perú: 2011 - 2021.

3.2. Variables y operacionalización de variables

Tabla 1. Variable

Variables	Tipo de variable	Dimensión	Indicador
PBI	Cuantitativa	Trimestral	PBI: 1980 - 2021

Elaboración: Propia.

Tabla 2. Operacionalización de variables

PROBLEMAS	OBJETIVOS	HIPOTESIS	OPERACIONALIZACION			METODO
			VARIABLES	DIMENSION	INDICADOR	
PG: ¿En medida la aplicación del modelo de redes neuronales resulta efectivo con el análisis del comportamiento y predicción del PBI oficial del Perú: 1980 – 2021?	OG: Evaluar el nivel de efectividad del modelo de redes neuronales con relación al análisis del comportamiento y predicción del PBI de Perú:1980 - 2021.	HG: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021.				Tipo: Aplicada
PE1: ¿De qué forma la aplicación del modelo de redes neuronales resulta efectivo con el análisis del comportamiento del PBI de Perú: 1980 - 2010?	OE1: Estimar el R ² para evaluar el nivel de efectividad del modelo de redes neuronales con relación al análisis del comportamiento del PBI de Perú: 1980 – 2010.	HE1: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento de los datos del PBI:1980 - 2010.	PBI	Trimestral	PBI: 1980 - 2021	Diseño: No experimental
PE2: ¿De qué forma la aplicación del modelo de redes neuronales resulta efectivo con el análisis de la predicción del PBI de Perú 2011 - 2021?	OE2: Estimar el R ² para evaluar el nivel de efectividad del modelo de redes neuronales en el análisis predicciones el PBI del Perú: 2011 - 2021	HE2: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis de la predicción de los datos del PBI de Perú: 2011 - 2021.				Nivel: Descriptivo

Elaboración: Propia.

3.3. Definición teórica de variables

En esta investigación sobre el modelo de redes neuronales artificiales para el análisis del comportamiento y predicción del PBI de Perú (1980-2021), se identifican y definen las siguientes variables:

Variable Principal

Producto Bruto Interno (PBI) de Perú

Definición: El PBI es una medida del valor monetario total de los bienes y servicios finales producidos por un país en un período específico, generalmente un trimestre o un año. Es un indicador clave del rendimiento económico de un país.

Importancia: El PBI se utiliza para evaluar el crecimiento económico, comparar el desempeño económico

CAPITULO IV. METODOLOGÍA

4.1. Ámbito o lugar de ejecución

El análisis de la investigación se desarrollará en el marco de los datos trimestrales del Producto Bruto Interno del Perú de 1980-2021.

4.2. Tipo y Nivel de investigación

Bavaresco (2001), Se señala que las investigaciones descriptivas se orientan hacia la identificación de aspectos que se desean comprender y de los cuales se buscan respuestas, mediante la descripción y el análisis sistemático de sus características.

Según Dankhe (citado por Hernández, Fernández y Baptista, 2003), los estudios descriptivos se dedican a " Recabar, evaluar o recolectar datos sobre diferentes aspectos, dimensiones o componentes del fenómeno objeto de estudio." (Hernández, Fernández y Baptista, 2003, p.117). El propósito de esto es recopilar toda la información disponible para llegar a los resultados de la investigación.

De acuerdo con Murillo (2008), la investigación aplicada, también conocida como "investigación práctica o empírica", se distingue por su enfoque en la aplicación o utilización de los saberes adquiridos. Asimismo, requiere la implementación y sistematización de prácticas basadas en la investigación, con el objetivo de generar nuevos conocimientos.

De acuerdo con Sabino (2006), los trabajos de investigación tienden a clasificarse en aplicados, en función de su propósito de estar vinculados a la resolución de un problema práctico. En la investigación aplicada, los conocimientos adquiridos son el recurso indispensable para llevar a cabo una acción específica.

Es por lo que, la investigación es de carácter descriptivo-aplicada, ya que tiene como objetivo principal describir los resultados de la evaluación del nivel de efectividad del modelo de redes neuronales. Por otro lado, el tipo de investigación es aplicada, ya que se trata de resolver problemas prácticos y concretos o abordar preguntas específicas relacionadas con la aplicación práctica del conocimiento.

4.4. Población y muestra

4.4.1. Descripción de la población

La población se ha obtenido de una fuente secundaria, en donde se determinaron los datos trimestrales del Producto Bruto Interno del Perú.

4.4.2. Muestra y método de muestro

Para poder determinar la selección de nuestra muestra, se ha utilizado una fuente secundaria, precisando a los datos trimestrales del Producto Bruto Interno del Perú de 1980-2021. El método de muestreo es muestreo no probabilístico por conveniencia. Este método se basa en la selección de datos disponibles y accesibles que cumplen con los criterios del estudio. En este caso, los datos trimestrales del PBI ya están recopilados y publicados por fuentes confiables, lo que facilita su uso para el análisis.

4.4.3. Criterios de inclusión y exclusión

Para la selección de los datos trimestrales del Producto Bruto Interno (PBI) de Perú de 1980 a 2021, se han definido los siguientes criterios de inclusión y exclusión:

Criterios de Inclusión

Temporalidad: Datos que correspondan al período comprendido entre el primer trimestre de 1980 y el cuarto trimestre de 2021.

Frecuencia: Datos con periodicidad trimestral para asegurar una resolución temporal uniforme en el análisis.

Fuente: Datos provenientes de fuentes oficiales y confiables, como el Banco Central de Reserva del Perú (BCRP) o el Instituto Nacional de Estadística e Informática (INEI).

Integridad: Datos completos y sin omisiones en cada trimestre dentro del período de estudio.

Criterios de Exclusión

Datos Fuera del Período Estudiado: Cualquier dato que no corresponda al período 1980-2021 será excluido.

Datos con Frecuencia Diferente: Datos anuales, mensuales o con cualquier otra frecuencia distinta a la trimestral.

Fuentes No Oficiales: Datos provenientes de fuentes no oficiales o que no puedan verificarse con fuentes primarias confiables.

Datos Incompletos o Faltantes: Trimestres con datos faltantes o incompletos serán excluidos del análisis para asegurar la precisión y consistencia de los resultados.

Estos criterios garantizan que los datos utilizados en la investigación sean consistentes, comparables y adecuados para el análisis del comportamiento y la predicción del PBI mediante modelos de redes neuronales.

4.5. Diseño de investigación

De acuerdo con Hernández, Fernández y Baptista (2010, p.149), la investigación no experimental requiere estudios en los que no se manipulan deliberadamente las variables

y solo se observan los fenómenos en su entorno natural para su posterior análisis. Kerlinger (1979, p.116) define la investigación no experimental o exponencial como aquella en la que es imposible manipular variables o asignar sujetos o condiciones aleatoriamente.

La investigación no experimental evalúa el fenómeno estudiado sin tratar de explicar sus causas, lo que permite medir lo deseado sin condicionar los resultados. Hernández et al. (2003) sostienen que los diseños longitudinales representan datos a lo largo del tiempo en distintos puntos o periodos, lo que posibilita la inferencia de los cambios, sus determinantes y sus consecuencias.

Dado que la variable no será manipulada ni controlada de manera deliberada, y se desea llevar a cabo un seguimiento a lo largo de un período de 40 años, se empleará el diseño de investigación no experimental-longitudinal.

4.6. Métodos, técnicas e instrumentos

4.6.1. Método

Se ha usado el método deductivo, como método general, ya que partimos de bases teóricas y la aplicamos en nuestra investigación. El método deductivo es una aproximación lógica de razonamiento que se basa en premisas generales para llegar a conclusiones específicas. Este método implica inferir conclusiones particulares a partir de principios generales o reglas universales. En otras palabras, se parte de lo general a lo específico.

4.6.2. Técnicas

El análisis documental es una técnica de investigación que consiste en la revisión y análisis de documentos, informes, bases de datos, registros públicos, sitios web y cualquier otro material que contenga información relevante para el tema de estudio. En este caso, la página web del BCRP constituye una fuente secundaria de información.

Estadística: mediante la cual se procesa y organiza los principales estadísticos, mediante tablas y gráficas.

- R cuadrado: Es una técnica estadística que mide directamente qué proporción de la variabilidad en los datos reales es capturada por las predicciones del modelo proporcionando una evaluación más directa de la capacidad predictiva del modelo, Cuanto más alto sea el R^2 , más confianza podemos tener en que el modelo captura lo que realmente está sucediendo en nuestros datos.

- **Distribución Normal:** También conocida como distribución gaussiana, la consideración de la distribución normal en un modelo de redes neuronales para la predicción del PBI proporciona base estadística sólida para interpretar y comunicar los resultados. Permite una evaluación más matizada de las proyecciones del PBI, incorporando conceptos de probabilidad y riesgo que son cruciales para la toma de decisiones
- **Graficas:** Se uso diversa graficas para representar los datos y resultados, como graficas de dispersión, histogramas, entre otras.

Análisis documental: mediante la recolección de datos de fuentes secundarias tales como libros, informes, reportes estadísticos y artículos científicos; y otros documentos de interés.

4.6.3. Instrumentos

4.6.3.1. Validación de los instrumentos para la recolección de datos

Fue necesario validar el instrumento de estudio mediante la evaluación de cuatro expertos, quienes analizaron el método de recolección de datos en su conjunto. Cada experto evaluó la relevancia, coherencia, adecuación y claridad de cada elemento, considerándolos apropiados.

Tabla 3. Validación del instrumento

PROFESIONALES	APLICABILIDAD INSTRUMENTO	DEL
Jeel Elvis Cueva Laguna	APLICABLE	
Roberto Angelo Calero Bravo	APLICABLE	
Miguel Bryan Narváez del Águila	APLICABLE	
Abilio Vicente Carhuas	APLICABLE	

Elaboración: Propia.

4.6.3.2. Confiabilidad de los instrumentos para la recolección de los datos

En esta investigación, la confiabilidad de los instrumentos de recolección de datos es esencial para garantizar la precisión y validez de los resultados. Dado que se utilizan datos secundarios del Producto Bruto Interno (PBI) de Perú de 1980 a 2021, se evalúa la confiabilidad de las fuentes y los métodos empleados para recopilar estos datos.

Fuentes de Datos

Banco Central de Reserva del Perú (BCRP): Es la principal fuente de datos macroeconómicos en Perú, reconocida por su rigurosidad y estándares de calidad en la recopilación y publicación de datos económicos.

Evaluación de la Confiabilidad

Estándares y Métodos de Recopilación:

- El BCRP siguen estándares internacionales para la recopilación y publicación de datos económicos, como las Normas Especiales para la Divulgación de Datos del FMI (Fondo Monetario Internacional).
- Los datos son recopilados utilizando metodologías robustas y transparentes, que son revisadas periódicamente para garantizar su precisión y relevancia.

Actualización y Consistencia:

- Los datos del PBI son actualizados de manera regular y sistemática, asegurando la disponibilidad de información actualizada y consistente a lo largo del tiempo.

Verificación y Validación:

- Los datos publicados por el BCRP pasan por rigurosos procesos de verificación y validación antes de ser divulgados.
- Las instituciones realizan auditorías internas y externas para garantizar la integridad y exactitud de la información.

Transparencia y Accesibilidad:

- Las fuentes de datos proporcionan documentación detallada sobre los métodos de recopilación y ajuste de datos, lo que permite a los investigadores entender y evaluar la calidad de los datos utilizados.
- La accesibilidad a los datos y a la documentación metodológica a través de sus plataformas en línea facilita la verificación independiente por parte de otros investigadores.

La confiabilidad de los instrumentos de recolección de datos en esta investigación es alta debido a la utilización de fuentes secundarias reconocidas y respetadas como el BCRP. Esta institución aplica metodologías estándar y transparentes, aseguran la consistencia y actualizan regularmente los datos, lo que proporciona una base sólida para el análisis del comportamiento y predicción del PBI de Perú mediante modelos de redes neuronales.

4.7. Técnicas de procesamiento y análisis de datos

4.7.1. Datos a registrar

Para asegurar la integridad metodológica y la transparencia en esta investigación sobre el análisis del comportamiento y predicción del Producto Bruto Interno (PBI) de Perú mediante modelos de redes neuronales, es fundamental registrar detalladamente varios aspectos cruciales. En primer lugar, se deben documentar minuciosamente los datos trimestrales del PBI de Perú correspondientes al extenso período comprendido entre 1980 y 2021. Estos datos deben ser obtenidos exclusivamente de fuentes de máxima confiabilidad como el Banco Central de Reserva del Perú (BCRP). Es imperativo registrar meticulosamente la fuente específica de cada conjunto de datos, garantizando así la trazabilidad y la verificabilidad continua de toda la información utilizada en el estudio. Este enfoque asegura que cada dato utilizado en el análisis del PBI sea respaldado por una fuente autorizada y actualizada, evitando así posibles errores derivados de la utilización de datos desactualizados o de origen dudoso. La precisión en la documentación de estas fuentes también facilita la replicación de la investigación por parte de otros investigadores y la validación independiente de los resultados obtenidos. Además, la rigurosidad en la documentación de los datos del PBI contribuye a la coherencia del análisis a lo largo del período temporal estudiado, permitiendo identificar y analizar tendencias económicas a largo plazo con mayor confianza. Esto es crucial para evaluar correctamente el comportamiento histórico y la dirección futura del PBI de Perú, aspectos centrales en el objetivo de predicción utilizando modelos de redes neuronales. Para acceder a los datos del Producto Bruto Interno de Perú proporcionados por el Banco Central de Reserva del Perú, se puede consultar el siguiente enlace:

[PBI \(millones US\\$\) \(bcrp.gob.pe\) -
https://estadisticas.bcrp.gob.pe/estadisticas/series/trimestrales/resultados/PN02635BQ/html](https://estadisticas.bcrp.gob.pe/estadisticas/series/trimestrales/resultados/PN02635BQ/html)

Base de datos

Base de datos usado en el modelo de redes neuronales

BASE DE DATOS

Tabla 4. Base de datos

Date	TRIMESTRE - AÑO	PBI US\$ (Millones)
30/03/1980	T180	3673,793827
30/06/1980	T280	4241,183556

30/09/1980	T380	4542,741163
30/12/1980	T480	5034,47443
30/03/1981	T181	4365,595169
30/06/1981	T281	5278,048986
30/09/1981	T381	5529,20217
30/12/1981	T481	5848,234819
30/03/1982	T182	4960,378643
30/06/1982	T282	5621,910353
30/09/1982	T382	5222,455018
30/12/1982	T482	5295,611686
30/03/1983	T183	4008,71197
30/06/1983	T283	4334,333144
30/09/1983	T383	4093,943251
30/12/1983	T483	4243,305112
30/03/1984	T184	3711,320144
30/06/1984	T284	4427,674541
30/09/1984	T384	4410,025605
30/12/1984	T484	4417,688214
30/03/1985	T185	3366,079567
30/06/1985	T285	3800,866267
30/09/1985	T385	3517,275763
30/12/1985	T485	3826,946442
30/03/1986	T186	3614,431098
30/06/1986	T286	4917,989385
30/09/1986	T386	5488,732788
30/12/1986	T486	6328,223453
30/03/1987	T187	5593,88703
30/06/1987	T287	7146,123476
30/09/1987	T387	7538,214897
30/12/1987	T487	7231,193897
30/03/1988	T188	5406,753825
30/06/1988	T288	5624,130371
30/09/1988	T388	5565,059361

30/12/1988	T488	5928,698176
30/03/1989	T189	5009,605912
30/06/1989	T289	5735,358869
30/09/1989	T389	7268,363068
30/12/1989	T489	7291,360386
30/03/1990	T190	9490,070689
30/06/1990	T290	7099,636949
30/09/1990	T390	5885,185156
30/12/1990	T490	6933,492338
30/03/1991	T191	7758,525113
30/06/1991	T291	7956,903112
30/09/1991	T391	9247,663956
30/12/1991	T491	8527,338489
30/03/1992	T192	9398,296333
30/06/1992	T292	9640,203181
30/09/1992	T392	8529,934151
30/12/1992	T492	8056,698952
30/03/1993	T193	8094,351269
30/06/1993	T293	8782,619092
30/09/1993	T393	8557,090076
30/12/1993	T493	8726,845611
30/03/1994	T194	9473,407231
30/06/1994	T294	10607,43324
30/09/1994	T394	10667,91088
30/12/1994	T494	11972,42025
30/03/1995	T195	12095,94461
30/06/1995	T295	13190,97555
30/09/1995	T395	13039,64104
30/12/1995	T495	13080,40698
30/03/1996	T196	12761,24974
30/06/1996	T296	13973,41036
30/09/1996	T396	13259,0592
30/12/1996	T496	13418,75044

30/03/1997	T197	12963,92682
30/06/1997	T297	14645,08156
30/09/1997	T397	14302,85814
30/12/1997	T497	14390,8591
30/03/1998	T198	13660,23257
30/06/1998	T298	14406,96908
30/09/1998	T398	13381,16799
30/12/1998	T498	12583,72386
30/03/1999	T199	11570,38464
30/06/1999	T299	12667,07511
30/09/1999	T399	11933,93707
30/12/1999	T499	12553,63266
30/03/2000	T100	12430,92072
30/06/2000	T200	13242,05993
30/09/2000	T300	12427,86269
30/12/2000	T400	12331,08662
30/03/2001	T101	11853,77321
30/06/2001	T201	13160,34117
30/09/2001	T301	12743,09167
30/12/2001	T401	13292,14768
30/03/2002	T102	12764,95485
30/06/2002	T202	14498,63081
30/09/2002	T302	12987,17715
30/12/2002	T402	13737,90939
30/03/2003	T103	13786,60514
30/06/2003	T203	15496,31855
30/09/2003	T303	14335,42517
30/12/2003	T403	14927,78196
30/03/2004	T104	15233,37444
30/06/2004	T204	17315,714
30/09/2004	T304	16045,32052
30/12/2004	T404	17561,48716
30/03/2005	T105	17282,69731

30/06/2005	T205	19654,89596
30/09/2005	T305	18247,66907
30/12/2005	T405	19054,72132
30/03/2006	T106	19607,39983
30/06/2006	T206	22585,46622
30/09/2006	T306	22112,21915
30/12/2006	T406	23263,24031
30/03/2007	T107	23004,19263
30/06/2007	T207	25423,23507
30/09/2007	T307	25609,25268
30/12/2007	T407	28351,198
30/03/2008	T108	28472,22613
30/06/2008	T208	32573,16126
30/09/2008	T308	31367,71163
30/12/2008	T408	29554,61279
30/03/2009	T109	26252,13505
30/06/2009	T209	29977,56385
30/09/2009	T309	30866,55886
30/12/2009	T409	34896,53104
30/03/2010	T110	32898,69524
30/06/2010	T210	37192,10106
30/09/2010	T310	37948,05148
30/12/2010	T410	40997,24798
30/03/2011	T111	38877,32595
30/06/2011	T211	42203,56786
30/09/2011	T311	43612,05634
30/12/2011	T411	46453,03572
30/03/2012	T112	43608,68075
30/06/2012	T212	47220,83366
30/09/2012	T312	49034,88607
30/12/2012	T412	53265,97571
30/03/2013	T113	48857,5022
30/06/2013	T213	51162,31292

30/09/2013	T313	49813,58518
30/12/2013	T413	52273,65433
30/03/2014	T114	47763,06435
30/06/2014	T214	51043,75791
30/09/2014	T314	51590,48868
30/12/2014	T414	51944,98394
30/03/2015	T115	45978,44046
30/06/2015	T215	48480,93858
30/09/2015	T315	47801,77254
30/12/2015	T415	49061,50295
30/03/2016	T116	43970,58497
30/06/2016	T216	49014,71883
30/09/2016	T316	49841,96624
30/12/2016	T416	51713,1388
30/03/2017	T117	49304,55684
30/06/2017	T217	52958,13632
30/09/2017	T317	54726,369
30/12/2017	T417	57341,35699
30/03/2018	T118	53205,2073
30/06/2018	T218	57771,36465
30/09/2018	T318	56082,98028
30/12/2018	T418	58370,73935
30/03/2019	T119	53284,80149
30/06/2019	T219	58509,47279
30/09/2019	T319	58453,99692
30/12/2019	T419	60718,1653
30/03/2020	T120	51463,05958
30/06/2020	T220	40995,05786
30/09/2020	T320	52675,20628
30/12/2020	T420	59833,78235
30/03/2021	T121	53787,59592
30/06/2021	T221	56127,59362
30/09/2021	T321	55428,62152

30/12/2021

T421

59320,30019

Fuente: Banco Central de Reserva del Perú (BCRP)

Elaboración: Propia.

4.7.2. Procedimiento

Para facilitar el análisis y modelamiento de los datos se usa librerías y módulos, que son archivos de Python que contiene definiciones y declaraciones que se pueden usar en otros programas. Estas bibliotecas y módulos proporcionan una amplia gama de funcionalidades y herramientas para el análisis y modelado de datos.

LIBRERIAS

Las que se usan en todo el análisis y modelamiento de datos son los siguientes:

```
# LIBRERIAS IMPORTADAS
```

```
import numpy as np
```

```
import matplotlib.pyplot as plt
```

```
import pandas as pd
```

```
import seaborn as sns
```

```
from sklearn.preprocessing import MinMaxScaler
```

```
from keras.models import Sequential
```

```
from keras.layers import Dense, LSTM, GRU
```

```
from sklearn.linear_model import LinearRegression
```

```
from sklearn.metrics import r2_score
```

```
from sklearn.metrics import mean_squared_error
```

```
import statsmodels.api as sm
```

Estas bibliotecas son esenciales para cargar, preprocesar, modelar, evaluar y visualizar datos, así como para entrenar y ajustar modelos de aprendizaje automático en este contexto específico de predicción del PBI de Perú utilizando redes neuronales artificiales.

SEPARACIÓN DE DATOS (DATOS OBSERVADOS Y ENTRENAMIENTO)

En la siguiente parte del código se procede a la separación de los datos, tanto de entrenamiento, como se muestra la totalidad de datos observados:

```
# Lectura de los datos (Base de datos)
```

```
# Se lee el archivo de Excel que contiene los datos y se almacenan en el dataframe 'dataset'
```

```
# El archivo se encuentra en la ruta 'D:/Carpeta Escritorio/tesis rna/datos/Base de datos.xlsx'
```

```
# La columna 'Date' se utiliza como índice y se interpreta como fechas
```

```

dataset = pd.read_excel('D:/base de datos/Base de datos.xlsx', index_col='Date',
parse_dates=['Date'])
dataset.head()
"""DATOS OBSERVADOS Y DATOS DE ENTRENAMIENTO (Separación de
datos)"""
"""TOTAL DE DATOS = 168"""
# La RNA se entrenará con datos desde el primer trimestre de 1980 hasta el cuarto
trimestre de 2010.
# Se selecciona una porción del conjunto de datos original, limitando las fechas hasta el
año 2010 (inclusive)
# Solo se considera la segunda columna de datos para el entrenamiento
datos_entrenamiento= dataset['2010'].iloc[:,1:2]
# Los datos desde el primer trimestre del 2011 hasta el cuarto trimestre del 2021 son datos
que el modelo desconoce.
# Se selecciona otra porción del conjunto de datos original, comenzando desde el año
1980 hasta el final
# También se considera solo la segunda columna de datos para la observación
datos_observados = dataset['1980:'].iloc[:,1:2]
# Gráfico de los datos observados
datos_observados['PBI PEN'].plot(legend=True)
# Gráfico de los datos de entrenamiento
# Se utiliza una línea punteada de color negro para distinguirlos de los datos observados
datos_entrenamiento['PBI PEN'].plot(linestyle='--', color='black', legend=True)
# Configuración del título y las leyendas del gráfico
plt.title('TOTAL DE DATOS')
plt.legend(['Datos Observados (1980-2020)', 'Datos de Entrenamiento (1980-2010)'])
# Mostrar el gráfico
plt.show()

```

El código realiza las siguientes acciones:

Se lee un archivo de Excel que contiene los datos y se almacenan en el dataframe 'dataset'. El archivo se encuentra en la ruta 'D:/Carpeta Escritorio/tesis rna/datos/Base de datos.xlsx' y se utiliza la columna 'Date' como índice y se interpreta como fechas. Luego se muestra una vista previa de los datos iniciales.

A continuación, se separan los datos en dos conjuntos: 'datos_entrenamiento' y 'datos_observados'. El conjunto de entrenamiento contiene los datos desde el primer trimestre de 1980 hasta el cuarto trimestre de 2010. El conjunto de observación contiene los datos desde el primer trimestre del 1980 hasta el final de los datos.

Luego, se realiza un gráfico de línea para visualizar los datos observados. La columna 'PBI PEN' se utiliza como los valores a graficar.

Posteriormente, se realiza otro gráfico de línea para visualizar los datos de entrenamiento. Nuevamente, se utiliza la columna 'PBI PEN'. En este caso, se utiliza una línea punteada de color negro para distinguirlos de los datos observados.

Se configura el título del gráfico como 'TOTAL DE DATOS' y se agrega una leyenda para identificar los datos observados y los datos de entrenamiento. Finalmente, se muestra el gráfico completo.

NORMALIZACIÓN DE DATOS

En este fragmento de código se realiza la normalización del conjunto de entrenamiento utilizando la clase “MinMaxScaler” de la biblioteca “scikit-learn” (sklearn).

```
# Normalización de los datos de entrenamiento
```

```
# Se utiliza el escalador MinMaxScaler para transformar los datos en una escala de 0 a 1
```

```
sc = MinMaxScaler(feature_range=(0, 1))
```

```
datos_entrenamiento_escalado = sc.fit_transform(datos_entrenamiento)
```

La normalización es un proceso común en el análisis de datos que ajusta los valores de una variable dentro de un rango específico, en este caso, entre 0 y 1. Esto se hace para asegurar que todas las características tengan la misma escala y evitar que alguna característica domine sobre las demás debido a diferencias en sus rangos de valores.

A continuación, se explica el código paso a paso:

```
sc = MinMaxScaler(feature_range=(0, 1))
```

Se crea una instancia del objeto “MinMaxScaler” y se asigna a la variable “sc”. El parámetro “feature_range=(0,1)” se utiliza para especificar el rango deseado para los valores normalizados. En este caso, se establece el rango entre 0 y 1.

```
datos_entrenamiento_escalado = sc.fit_transform(datos_entrenamiento)
```

El método “fit_transform()” se aplica al conjunto de entrenamiento “datos_entrenamiento”. Este método ajusta el escalador (“sc”) al conjunto de datos y, al mismo tiempo, transforma los datos aplicando la normalización. El conjunto de entrenamiento normalizado se asigna a la variable “datos_entrenamiento_escalado”.

El código normaliza el conjunto de entrenamiento utilizando “MinMaxScaler”, lo que asegura que los valores estén dentro del rango especificado (0-1). La normalización es importante para garantizar un procesamiento de datos adecuado antes de utilizarlos en modelos de aprendizaje automático y análisis estadístico.

La fórmula matemática utilizada para normalizar los datos utilizando la técnica de MinMax normalization es la siguiente:

$$X_{scaled} = \frac{x - \min(x)}{\max(x) - \min(x)}$$

Donde:

- **x** es el valor individual que se está normalizando.
- **min(x)** es el valor mínimo en el conjunto de datos.
- **max(x)** es el valor máximo en el conjunto de datos.
- **x_scaled** es el valor normalizado resultante.

Para cada valor x en el conjunto de datos, se resta el valor mínimo min(x) y se divide por la diferencia entre el valor máximo max(x) y el valor mínimo min(x). Esto asegura que los datos se ajusten en un rango específico, en este caso, entre 0 y 1.

En esta parte del código se procede a graficar los datos escalados

```
# Gráfico de los datos normalizados
# Se traza la secuencia de valores normalizados en función del índice de muestra
plt.plot(datos_entrenamiento_escalado)
plt.xlabel('Índice de muestra')
plt.ylabel('Valor normalizado')
plt.title('Datos de entrenamiento normalizados')
plt.show()
```

La fórmula normalizada garantiza que los valores más pequeños se mapeen a 0 y los valores más grandes se mapeen a 1, con los valores intermedios escalados proporcionalmente.

Esta técnica de normalización es comúnmente utilizada en el análisis de datos y el modelado de machine learning para asegurar que las características tengan la misma escala y evitar que alguna característica domine sobre las demás debido a diferencias en sus rangos de valores.

PREPARACIÓN DE LOS DATOS DE ENTRENAMIENTO

En este fragmento de código se está preparando el conjunto de entrenamiento para la Red Neuronal Artificial (RNA). Se ajusta el formato de los datos para que sean compatibles con el modelo de la RNA en Keras.

A continuación, se explica el código paso a paso:

La RNA tendrá como entrada "dato_entrada" datos consecutivos, y como salida 1 dato (la predicción a partir de esos "dato_entrada" datos).

Se conformará de esta forma el set de entrenamiento

```
dato_entrada = 2
```

Listas para almacenar los datos de entrenamiento

```
X_train = []
```

```
Y_train = []
```

Obtener la longitud total de los datos de entrenamiento normalizados

```
m = len(datos_entrenamiento_escalado)
```

Generar los datos de entrenamiento y salida correspondientes

```
for i in range(dato_entrada, m):
```

```
    # X: bloques de "dato_entrada" datos consecutivos
```

```
    bloque_entrenamiento = datos_entrenamiento_escalado[i - dato_entrada : i, 0]
```

```
    X_train.append(bloque_entrenamiento)
```

```
    # Y: el siguiente dato después del bloque de "dato_entrada"
```

```
    siguiente_dato = datos_entrenamiento_escalado[i, 0]
```

```
    Y_train.append(siguiente_dato)
```

Convertir las listas en matrices numpy

```
X_train = np.array(X_train)
```

```
Y_train = np.array(Y_train)
```

Ajustar la forma de X_train para que se ajuste al modelo en Keras

La nueva forma será (número de muestras, número de pasos de tiempo, número de características)

```
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1))
```

Este código se encarga de preparar los datos de entrenamiento para ser utilizados en una red neuronal recurrente (RNA) con arquitectura LSTM.

La variable "dato_entrada" define la cantidad de datos consecutivos que se utilizarán como entrada en la RNA. En este caso, se toman "dato_entrada" datos consecutivos para predecir el siguiente dato. Se inicializan dos listas vacías, "X_train" y "Y_train", que se utilizarán para almacenar los datos de entrenamiento y las salidas correspondientes. La

variable “m” guarda la longitud total de los datos de entrenamiento normalizados. Se itera a través de los datos de entrenamiento normalizados desde el índice “dato_entrada” hasta “m”. En cada iteración, se crea un bloque de “dato_entrada” datos consecutivos a partir de los datos de entrenamiento normalizados. Estos datos se agregan a la lista “X_train”. También se guarda el siguiente dato después del bloque de “dato_entrada” en la lista “Y_train” y finalmente, las listas “X_train” y “Y_train” se convierten en matrices numpy para su procesamiento posteriormente se ajusta la forma de “X_train” para que se ajuste al formato requerido por el modelo de Keras. La nueva forma será “(número de muestras, número de pasos de tiempo, número de características)”, donde el número de pasos de tiempo es “dato_entrada” y el número de características es 1.

Este código prepara los datos de entrenamiento para la RNA LSTM, dividiéndolos en bloques consecutivos de “dato_entrada” datos como entrada, y el siguiente dato como salida.

DEFINICIÓN DE LA ESTRUCTURA DE LA RNA LSTM

```
# Definición de la estructura de la RNA LSTM
# Dimensiones de entrada para la RNA LSTM
dim_entrada = (X_train.shape[1], 1)
# Creación del modelo secuencial
modelo = Sequential()
# Capa LSTM con 20 unidades y función de activación tangente hiperbólica
modelo.add(LSTM(units=20, input_shape=dim_entrada, activation='tanh'))
# Capa densa de salida con 1 unidad
modelo.add(Dense(units=1))
# Compilación del modelo con optimizador RMSprop y función de pérdida MSE
modelo.compile(optimizer='RMSprop', loss='mse')
# Impresión de mensaje de inicio del entrenamiento
print("Comenzando entrenamiento del modelo...")
# Entrenamiento del modelo con los datos de entrada X_train y las salidas Y_train
historia = modelo.fit(X_train, Y_train, epochs=40, batch_size=10, validation_split=0.2,
verbose=True)
# Impresión de mensaje de fin del entrenamiento
print("Entrenamiento del modelo terminado")
```

En este código se define y entrena un modelo de red neuronal LSTM utilizando Keras. A continuación, se explica cada línea:

Este código se encarga de definir la estructura de una red neuronal LSTM (Long Short-Term Memory) y entrenarla con los datos preparados previamente.

- La variable “dim_entrada” se utiliza para almacenar las dimensiones de entrada de la RNA LSTM. En este caso, se establece el número de pasos de tiempo como “X_train.shape[1]” (basado en la forma de los datos de entrada) y el número de características como 1, ya que solo se utiliza una característica en este ejemplo.

- Se crea un modelo secuencial llamado “modelo” utilizando la clase “Sequential” de Keras. La clase Sequential es una clase en la biblioteca Keras que se utiliza para crear modelos de redes neuronales secuenciales. Un modelo secuencial es aquel en el que las capas de la red neuronal se apilan una encima de la otra, formando una secuencia lineal de capas. Cada capa se conecta directamente a la capa anterior y a la siguiente, sin tener conexiones adicionales.

ALGORITMO DE LA RED NEURONAL

$$a^n = f^n(w^n f^{n-1}(w^{n-1} f^{n-2}(w^{n-2} f^{n-3} \dots (w^1 p + b^1) \dots + b^{n-2}) + b^{n-1}) + b^n)$$

Donde a es la salida de la neurona, w es el peso de la conexión con otra neurona, p es la entrada de la neurona y b es el entrenamiento que recibe la neurona y f es la función de transferencia de información de una neurona a otra.

La clase Sequential proporciona una interfaz sencilla y conveniente para construir modelos secuenciales en Keras. Permite agregar capas al modelo utilizando el método add, y Keras se encarga automáticamente de establecer las conexiones entre las capas.

- Se agrega una capa LSTM al modelo con 20 unidades y una función de activación tangente hiperbólica. La capa LSTM se configura con el parámetro “input_shape” establecido en “dim_entrada”, lo que define la forma de entrada de los datos.

La función tangente hiperbólica, denotada como $\tanh(x)$, es una función matemática que mapea cualquier número real en el rango [-1, 1]. Se define de la siguiente manera:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Donde e es la base del logaritmo natural (~2.71828) y x es el valor de entrada.

En el contexto del modelo LSTM (Long Short-Term Memory), la función de activación tangente hiperbólica desempeña un papel importante. Se utiliza como función de activación en las unidades LSTM para introducir no linealidad en el modelo y permitir

que las neuronas LSTM capturen y procesen patrones complejos en los datos secuenciales.

La función tangente hiperbólica tiene características deseables para el modelado de secuencias. En particular, su rango de salida $[-1, 1]$ permite que las unidades LSTM generen valores que pueden ser positivos o negativos, lo que les permite capturar tanto relaciones lineales como no lineales en los datos de entrada.

Además, la función tangente hiperbólica es diferenciable, lo que facilita el cálculo de los gradientes durante el entrenamiento mediante retropropagación. Esto es esencial para ajustar los pesos y los sesgos de las unidades LSTM a medida que se actualizan durante el proceso de entrenamiento.

La función tangente hiperbólica en el modelo LSTM ayuda a introducir no linealidad y capturar patrones complejos en los datos secuenciales, lo que mejora la capacidad del modelo para realizar predicciones precisas en problemas de secuencias, como el procesamiento del lenguaje natural, el análisis de series de tiempo y la generación de texto.

- Se agrega una capa densa de salida al modelo con 1 unidad.
- Se compila el modelo utilizando el optimizador RMSprop y la función de pérdida MSE (Mean Squared Error).

El optimizador RMSprop utiliza una variante del método de descenso de gradiente estocástico para ajustar los pesos de la red neuronal en el modelo LSTM. Matemáticamente, RMSprop actualiza los pesos de acuerdo con la siguiente regla:

$$v_{dw} = \beta v_{dw} + (1 - \beta) \cdot (\nabla_{dw} J)^2$$

$$v_{db} = \beta v_{db} + (1 - \beta) \cdot (\nabla_{db} J)^2$$

$$W = W - \alpha \cdot \frac{\nabla_{dw} J}{\sqrt{v_{dw} + \epsilon}}$$

$$b = b - \alpha \cdot \frac{\nabla_{db} J}{\sqrt{v_{db} + \epsilon}}$$

Donde:

- " v_{dw} " y " v_{db} " son los promedios acumulados de los gradientes al cuadrado para los pesos " W " y los sesgos " b " respectivamente.
- " $(\nabla_{dw} J)$ " y " $(\nabla_{db} J)$ " son los gradientes de la función de pérdida " J " con respecto a " W " y " b " respectivamente.
- " α " es la tasa de aprendizaje que controla la magnitud de la actualización de los pesos.

- “ β ” es un hiperparámetro que especifica el factor de decaimiento para los promedios acumulados.

- “ ϵ ” es una pequeña cantidad constante para evitar la división entre cero.

La función de RMSprop es adaptativa y ajusta la tasa de aprendizaje para cada parámetro de forma individual. Esto permite que el modelo aprenda de manera más eficiente al realizar actualizaciones más grandes para los parámetros con gradientes más pequeños y actualizaciones más pequeñas para los parámetros con gradientes más grandes.

RMSprop controla la tasa de aprendizaje de manera adaptativa al utilizar promedios acumulados de los gradientes al cuadrado. Esto ayuda a mejorar la convergencia y estabilidad del modelo LSTM durante el entrenamiento.

También se tienen la función de pérdida (“loss”) utilizada durante el entrenamiento de un modelo de aprendizaje automático puede variar según el problema y el tipo de modelo. No hay una única representación matemática que abarque todas las posibles funciones de pérdida.

Sin embargo, en el caso específico del modelo que estás utilizando, que utiliza la función de pérdida de error cuadrático medio (mean squared error, MSE), se puede representar matemáticamente de la siguiente manera:

Sea X el conjunto de datos de entrada y Y el conjunto de datos de salida. Dado un modelo entrenado, que produce una predicción \hat{Y} para cada entrada X, la función de pérdida MSE se define como:

La fórmula del error cuadrático medio (MSE) en formato es:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Donde:

- (n) es el número de ejemplos de entrenamiento,
- (Y_i) es el valor esperado de la salida para el ejemplo (i)
- (\hat{Y}_i) es la predicción del modelo para el ejemplo (i)
- (\sum) representa la suma de los errores cuadráticos para todos los ejemplos.

Esta fórmula calcula el promedio de los errores cuadráticos entre los valores esperados y las predicciones del modelo. El objetivo es minimizar este error cuadrático medio durante el entrenamiento para lograr un mejor ajuste del modelo a los datos.

Donde n es el número de ejemplos de entrenamiento, Σ representa la suma y $(Y - \hat{Y})^2$ es el error cuadrático entre la salida esperada Y y la predicción del modelo \hat{Y} para cada ejemplo.

- Se imprime un mensaje para indicar el inicio del entrenamiento del modelo.
- Se entrena el modelo utilizando los datos de entrada “X_train” y las salidas correspondientes “Y_train”. Se especifica un total de 40 épocas de entrenamiento, un tamaño de lote de 10 y una división de validación del 20% (“validation_split=0.2”). El argumento “verbose=True” permite imprimir información detallada sobre el progreso del entrenamiento.
- Una vez finalizado el entrenamiento, se imprime un mensaje para indicar que el entrenamiento del modelo ha terminado.

En resumen, este código define la estructura de una RNA LSTM, compila el modelo con una configuración específica y luego realiza el entrenamiento del modelo utilizando los datos de entrada preparados.

CURVA DE APRENDIZAJE DEL MODELO

```
# Curva de aprendizaje de la RNA
# Obtención de las curvas de pérdida durante el entrenamiento
loss = historia.history['loss']
val_loss = historia.history['val_loss']
# Gráfico de las curvas de pérdida
plt.plot(loss, label='Entrenamiento')
plt.plot(val_loss, label='Validación')
plt.xlabel('Épocas')
plt.ylabel('Pérdida')
plt.legend()
plt.title('Curva de aprendizaje del modelo')
plt.show()
# Gráfico de la magnitud de pérdida a lo largo de las épocas
plt.plot(historia.history["loss"])
plt.xlabel("# Época")
plt.ylabel("Magnitud de pérdida")
plt.title('Curva de aprendizaje del modelo')
plt.show()
```

Este código muestra la curva de aprendizaje de la red neuronal artificial (RNA) entrenada. La curva de aprendizaje es una representación gráfica de la pérdida del modelo durante el proceso de entrenamiento.

- Primero, se logra las curvas de pérdida del entrenamiento y de la validación almacenadas en el historial del entrenamiento de la RNA.

- Luego, se grafican estas curvas de pérdida en un gráfico. El eje x representa las épocas, es decir, las iteraciones del entrenamiento, y el eje y representa la magnitud de la pérdida. Hay dos líneas en el gráfico: una para la pérdida en el conjunto de entrenamiento y otra para la pérdida en el conjunto de validación. El objetivo es que ambas líneas disminuyan a medida que avanza el entrenamiento, lo que indica una mejoría en el rendimiento del modelo.

- Además, se muestra otro gráfico que representa únicamente la magnitud de la pérdida a lo largo de las épocas. Este gráfico brinda una visualización más detallada de cómo la pérdida disminuye a medida que avanza el entrenamiento.

Estos gráficos proporcionan información importante sobre el rendimiento del modelo durante el entrenamiento. Si la curva de pérdida en el conjunto de entrenamiento disminuye de manera significativa y la curva de pérdida en el conjunto de validación también disminuye o se mantiene estable, es un indicativo de un buen entrenamiento. Sin embargo, si la curva de pérdida en el conjunto de validación comienza a aumentar mientras la curva de pérdida en el conjunto de entrenamiento sigue disminuyendo, podría ser un signo de sobreajuste (overfitting) del modelo.

Estos gráficos ayudan a evaluar el progreso del entrenamiento y a tomar decisiones sobre ajustes en la arquitectura del modelo o en los hiperparámetros para mejorar su desempeño.

TRANSFORMACIÓN Y PREPARACIÓN DE LOS DATOS DE VALIDACIÓN PARA SU USO EN EL MODELO

Este código se encarga de preparar los datos de prueba y realizar predicciones utilizando el modelo entrenado.

```
# Preparación de los datos de prueba
```

```
x_test = datos_observados.values
```

```
x_test = sc.transform(x_test)
```

```
X_test = []
```

```
# Generación de los datos de prueba en bloques de tamaño "dato_entrada"
```

```
for i in range(dato_entrada, len(x_test)):
```

```

X_test.append(x_test[i-dato_entrada:i, 0])
X_test = np.array(X_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
"""Realización de predicciones después del entrenamiento"""
# Se utiliza el modelo entrenado para realizar predicciones sobre los datos de prueba
prediccion = modelo.predict(X_test)
# Las predicciones resultantes se almacenan en la variable 'prediccion'
# Estas representan los valores estimados por la RNA para los datos de prueba
# El modelo utiliza los datos de entrada 'X_test' y genera las predicciones
correspondientes
# Obtención de los residuos del modelo
# Se calcula la diferencia entre los datos de prueba reales y las predicciones realizadas
por el modelo
residuos = x_test[:-2, 0] - prediccion.flatten()
# Cálculo de la media y la desviación estándar de los residuos
mean_residuos = np.mean(residuos)
std_residuos = np.std(residuos)
# Establecimiento de umbrales superior e inferior para la detección de valores atípicos
# Los umbrales se calculan como 0.3 veces la desviación estándar por encima y por debajo
de la media de los residuos
umbral_superior = mean_residuos + 0.3 * std_residuos
umbral_inferior = mean_residuos - 0.3 * std_residuos
# Eliminación de los valores atípicos basados en los umbrales establecidos
residuos_sin_atipicos = residuos[(residuos >= umbral_inferior) & (residuos <=
umbral_superior)]
# Agregar una columna de unos a x_test como constante
# Esto se hace para poder estimar el intercepto
x_test_con_constante = sm.add_constant(x_test[:-2, 0])
- Primero, se toman los datos observados y se aplican transformaciones utilizando el
objeto "sc" (presumiblemente un objeto de escalado). Esto asegura que los datos de
prueba estén en la misma escala que los datos utilizados durante el entrenamiento.
- A continuación, se generan los datos de prueba en bloques de tamaño "dato_entrada"
(presumiblemente el mismo valor utilizado durante el entrenamiento). Se recorre el

```

conjunto de datos de prueba y se extraen bloques consecutivos de tamaño "dato_entrada" para formar las entradas de prueba "X_test".

- Después, se realiza la predicción utilizando el modelo entrenado. Se utiliza la función "predict" del modelo para obtener las predicciones correspondientes a los datos de prueba "X_test". Las predicciones resultantes se almacenan en la variable "prediccion".

- A continuación, se calculan los residuos del modelo. Esto se hace restando las predicciones del modelo ("prediccion") de los datos de prueba reales ("x_test[: -2, 0]"). Los residuos representan las diferencias entre los valores reales y los valores estimados por el modelo.

- Luego, se calcula la media y la desviación estándar de los residuos.

- A continuación, se establecen umbrales superior e inferior para detectar valores atípicos. Estos umbrales se calculan como 0.3 veces la desviación estándar por encima y por debajo de la media de los residuos. Los valores que se encuentren fuera de estos umbrales se consideran valores atípicos y se eliminan del conjunto de residuos.

- Finalmente, se agrega una columna de unos a "x_test" como constante. Esto se hace utilizando la función "add_constant" de la biblioteca "statsmodels". Esta columna de unos se agrega para poder estimar el intercepto en un posible análisis adicional. El resultado se almacena en la variable "x_test_con_constante".

Este código prepara los datos de prueba, realiza predicciones utilizando el modelo entrenado y calcula los residuos del modelo. Además, se realiza un procesamiento adicional para eliminar valores atípicos y agregar una columna de unos a los datos de prueba.

VOLVER LOS DATOS A LOS VALORES NORMALES Y MOSTRAMOS LAS VARIABLES INTERNAS DEL MODELO

```
# Desnormalizar las predicciones
prediccion = sc.inverse_transform(prediccion)
print("Predicciones Desnormalizadas:")
print(prediccion)

# Variables internas del modelo
print("Variables internas del modelo:")
for capa in modelo.layers:
    # Obtener la configuración de la capa y los pesos asociados
    config_capa = capa.get_config()
```

```

pesos_capa = capa.get_weights()
print("Configuración de la capa:", config_capa)
print("Pesos de la capa:", pesos_capa)

```

Este código realiza dos tareas:

1. Desnormalización de las predicciones:

- La variable "prediccion" contiene las predicciones realizadas por el modelo, que están normalizadas.

- Se utiliza la función "inverse_transform" del objeto "sc" (un objeto de la clase MinMaxScaler) para desnormalizar las predicciones y obtener los valores originales.

- Las predicciones desnormalizadas se asignan nuevamente a la variable "prediccion".

- Se imprime el resultado de las predicciones desnormalizadas.

2. Obtención de las variables internas del modelo:

- Se realiza un bucle a través de las capas del modelo.

- Para cada capa, se obtiene la configuración de la capa y los pesos asociados utilizando los métodos "get_config" y "get_weights" respectivamente.

- Se imprime la configuración de la capa y los pesos asociados.

Este código desnormaliza las predicciones del modelo para obtener los valores originales y muestra la configuración de las capas y los pesos asociados a cada capa del modelo. Esto proporciona información sobre los componentes internos del modelo y cómo se relacionan con las predicciones realizadas.

GRAFICOS

Este código muestra una serie de funciones para graficar diferentes aspectos de los resultados de las predicciones en comparación con los datos observados. Estas funciones son utilizadas para visualizar y analizar los resultados del modelo.

```
# Graficar todos los resultados: datos observados y predicciones
```

```
graficar_todo(datos_observados.values, prediccion)
```

```
# Graficar solo el comportamiento: datos observados y predicciones en el mismo gráfico
```

```
graficar_solo_comportamiento(datos_observados.values, prediccion)
```

```
# Graficar solo las predicciones
```

```
graficar_solo_prediccion(datos_observados.values, prediccion)
```

```
# Graficar la dispersión entre los datos reales y los datos predichos
```

```
graficar_dispersion(datos_observados.values, prediccion)
```

Graficar solo la dispersión del comportamiento: datos observados y predicciones en el mismo gráfico

```
graficar_dispesion_comportamiento(datos_observados.values, prediccion)
```

Graficar solo la dispersión de las predicciones

```
graficar_dispesion_prediccion(datos_observados.values, prediccion)
```

A continuación, se explica cada una de estas funciones:

1. “graficar_todo (datos_observados, prediccion)”: Grafica todos los resultados en un mismo gráfico. Muestra tanto los datos observados como las predicciones en el mismo gráfico.
2. “graficar_solo_comportamiento(datos_observados, prediccion)”: Grafica solo el comportamiento de los datos observados y las predicciones en el mismo gráfico. Este gráfico permite comparar cómo se ajustan las predicciones al comportamiento general de los datos observados.
3. “graficar_solo_prediccion(datos_observados, prediccion)”: Grafica solo las predicciones en un gráfico separado. Esto permite visualizar únicamente las predicciones realizadas por el modelo.
4. “graficar_dispesion(datos_observados, prediccion)”: Grafica la dispersión entre los datos reales y los datos predichos. Este gráfico muestra la diferencia o discrepancia entre los valores observados y los valores predichos.
5. “graficar_dispesion_comportamiento(datos_observados, prediccion)”: Grafica solo la dispersión del comportamiento en un gráfico separado. Muestra la dispersión entre los datos observados y las predicciones, centrándose en el comportamiento general de los datos.
6. “graficar_dispesion_prediccion(datos_observados, prediccion)”: Grafica solo la dispersión de las predicciones en un gráfico separado. Permite analizar la dispersión de las predicciones realizadas por el modelo.

Estas funciones proporcionan diferentes perspectivas para analizar y visualizar los resultados del modelo, lo que puede ser útil para evaluar su desempeño y comprender la calidad de las predicciones en comparación con los datos observados.

Softwares utilizados

Los softwares que se utilizó fueron:

Microsoft Excel (Como gestor de base de datos)

Visual Studio Code (Como interprete de lenguaje de programación)

Python (Como lengua de programación para el análisis correspondiente)

4.7.3. Plan de tabulación y análisis de datos estadísticos

El plan de tabulación y análisis de datos para esta investigación sobre el comportamiento y predicción del Producto Bruto Interno (PBI) de Perú incluye las siguientes etapas:

Recolección y Organización de Datos:

- Obtención de datos trimestrales del PBI de Perú (1980-2021) de fuentes confiables como el BCRP.
- Almacenamiento de datos en una base estructurada, etiquetados con fechas y unidades de medida.

Tabulación de Datos:

- Creación de tablas con valores trimestrales del PBI.

Análisis Estadístico:

- **Análisis Descriptivo:** Uso de gráficos de series temporales para identificar tendencias y patrones.
- **Análisis Inferencial:** Implementación y evaluación de modelos de redes neuronales, utilizando métricas como el coeficiente de determinación (R^2).

Presentación de Resultados:

- Visualización de datos mediante gráficos y diagramas comparativos.

CAPITULO V. RESULTADOS Y DISCUSION

5.1. Análisis descriptivo

En el procesamiento de datos tenemos dos análisis, uno enfocado al comportamiento de PBI trimestral que toma desde el primer trimestre de 1980 hasta el cuarto trimestre de 2010 en el cual el modelo en mención tiene un aprendizaje supervisado, se le presenta los datos que se espera obtener para su estimación y el otro análisis está centrado en la predicción del PBI que comprende desde el primer trimestre de 2011 al cuarto trimestre del 2021 donde el modelo predice el comportamiento sin que se le muestre los resultados reales del PBI en esos años.

Gráfico 1. PBI trimestral de Perú 1980 - 2021



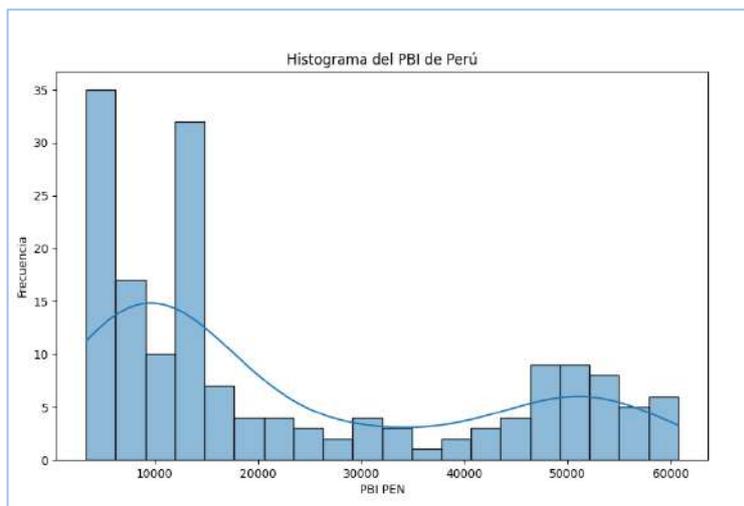
Elaboración: Propia.

El gráfico 1 muestra el comportamiento de PBI trimestral de Perú desde 1980 hasta 2021, como también la separación de datos para el entrenamiento del modelo y los datos de validación, el modelo será entrenado y analizará las estimaciones del comportamiento de la variable con solo el 80% del total de datos y el 20% restante será usado para validar las predicciones hechas por el modelo.

El análisis descriptivo se enfoca en resumir y visualizar los datos del Producto Bruto Interno (PBI) de Perú para el período 1980-2021, con el objetivo de identificar tendencias, patrones y posibles anomalías.

Se presenta el siguiente histograma donde se muestra la distribución del Producto Interno Bruto (PBI) de Perú. El eje horizontal representa los valores del PBI, mientras que el eje vertical muestra la frecuencia o cantidad de observaciones para cada rango de valores.

Gráfico 2. Histograma del PBI de Perú



Elaboración: Propia.

Teniendo en cuenta que se trata del PBI trimestral desde 1980 hasta 2021, con valores en millones de dólares, se puede hacer una interpretación más detallada del histograma:

- Los dos picos principales indican dos períodos distintos en la historia económica reciente de Perú, posiblemente relacionados con ciclos de auge y recesión.
- El pico más alto, alrededor de 10,000 millones de dólares, podría corresponder a los trimestres de recesión o desaceleración económica, donde el PBI era más bajo.
- El segundo pico, cerca de 50,000 millones, podría representar los trimestres de mayor crecimiento y auge económico, con un PBI más elevado.
- La cola larga hacia la derecha sugiere algunos trimestres excepcionales de muy alto PBI, probablemente impulsados por factores como precios elevados de exportaciones, inversiones significativas, etc.
- La distribución asimétrica refleja que los períodos de menor PBI han sido más frecuentes que los de muy alto PBI en el rango de tiempo analizado.

Este histograma parece capturar los ciclos económicos y la evolución del PBI trimestral de Perú en las últimas cuatro décadas, mostrando períodos de auge y recesión, así como la asimetría entre ambos tipos de fases económicas.

También se tienen las principales estadísticas descriptivas y su interpretación:

Tabla 5. Principales Estadísticas Descriptivas

PRINCIPALES ESTADÍSTICAS DESCRIPTIVAS

Numero de datos (count)	168	Esta es la cantidad total de observaciones. En este caso, hay 168 trimestres de datos del PBI de Perú.
Promedio (mean)	22827.721099	Éste es el promedio o valor medio del PBI en millones de dólares para todo el período analizado. Es decir, en promedio, el PBI trimestral de Perú fue de 22,827.72 millones de dólares.
Desviación estándar (std)	18694.976637	Esta cifra representa la desviación estándar, una medida de cuánto varían o se dispersan los datos respecto al valor promedio. Una desviación estándar alta indica que los valores están más dispersos. Aquí vemos que es un valor alto, 18,694.98, lo que sugiere una gran variabilidad en el PBI trimestral.
Valor mínimo (min)	3366.079567	Este es el valor mínimo del PBI trimestral, que fue de 3,366.08 millones de dólares.
valor del percentil 25 (25%)	7476.501270	Este es el valor del percentil 25, lo que significa que el 25% de los datos están por debajo de 7,476.50 millones de dólares
valor del percentil 50 (50%)	13539.491506	Este es el percentil 50, también conocido como la mediana. La mitad de los datos están por encima y la otra mitad por debajo de 13,539.49 millones de dólares.
valor del percentil 75 (75%)	41298.827949	El percentil 75 indica que el 75% de los datos están por debajo de 41,298.83 millones de dólares.
Valor máximo (max)	60718.165299	Este es el valor máximo del PBI trimestral en el dataset, que alcanzó los 60,718.17 millones de dólares.

Elaboración: Propia.

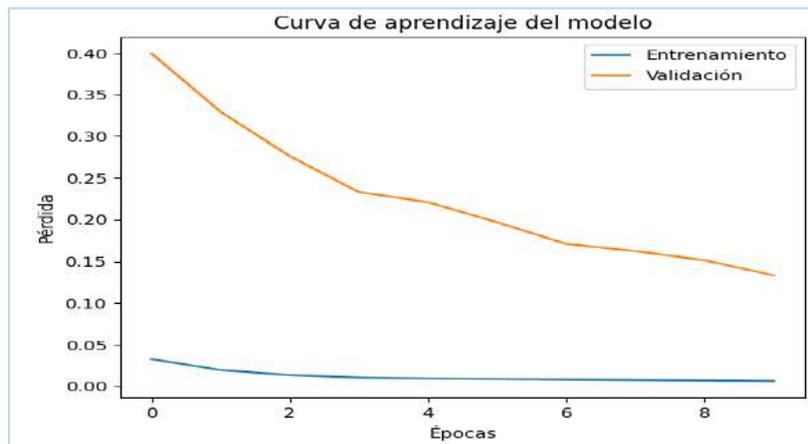
Estas estadísticas nos brindan un panorama general de la distribución del PBI trimestral de Perú, mostrando su tendencia central, dispersión, valores extremos y cuartiles clave. Esto nos ayuda a comprender mejor las características y el comportamiento de esta variable económica importante.

5.2. Análisis inferencial y/o contrastación hipótesis

Entrenamiento del modelo

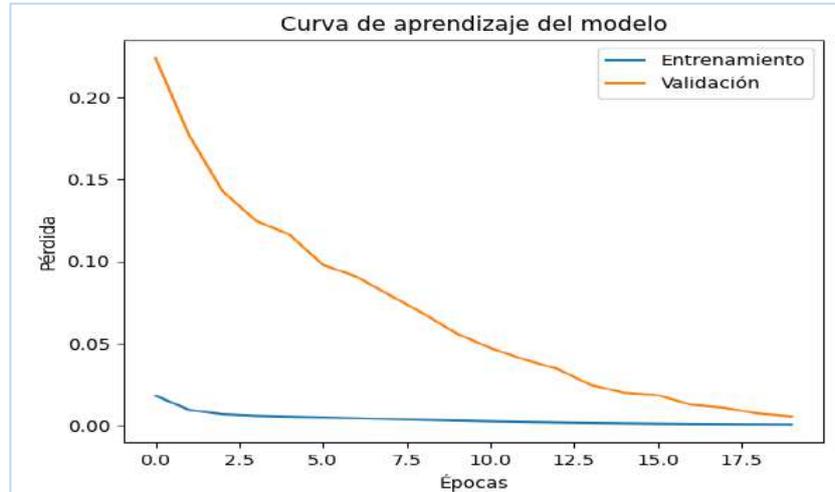
Para mostrar el rendimiento del modelo, se entrenó en con 4 épocas diferentes las cuales son 10, 20, 30 y 40 en las cuales se muestra el progreso que tuvo el modelo y como mejora su rendimiento mientras más épocas se entrena.

Gráfico 3. Curva de aprendizaje (10 épocas)



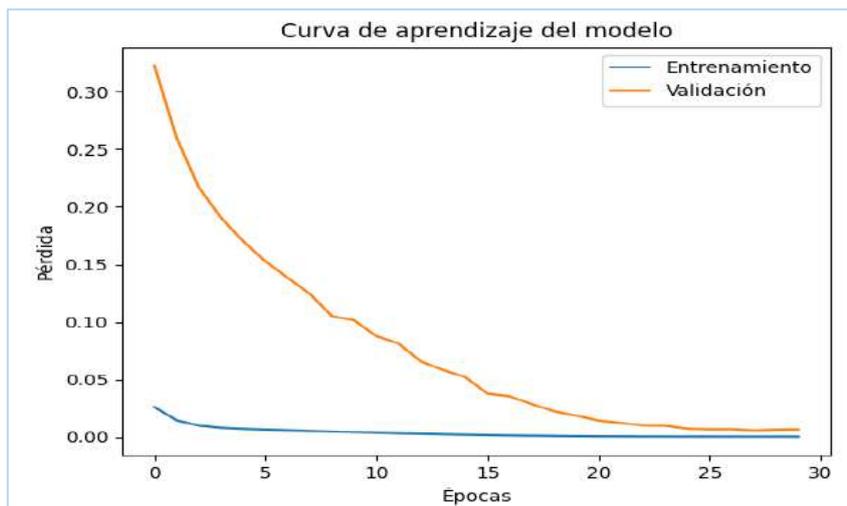
Elaboración: Propia.

Gráfico 4. Curva de aprendizaje (20 épocas)



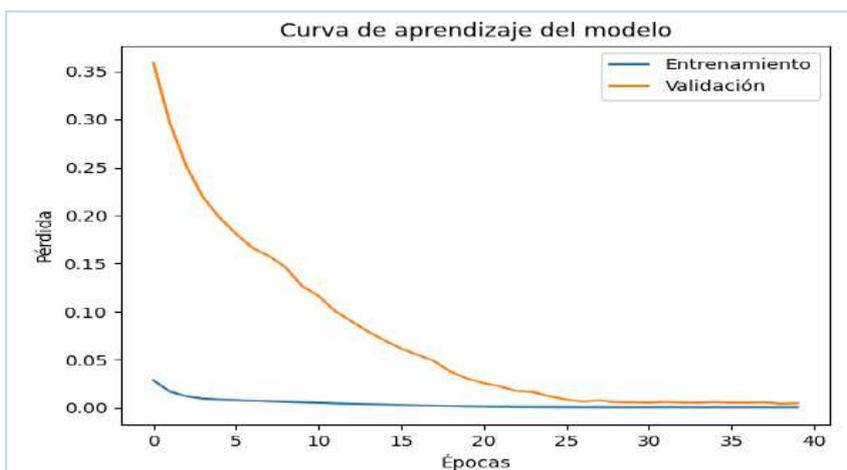
Elaboración: Propia.

Gráfico 5. Curva de aprendizaje (30 épocas)



Elaboración: Propia.

Gráfico 6. Curva de aprendizaje (40 épocas)



Elaboración: Propia.

La interpretación de las curvas de pérdida durante el entrenamiento es crucial para evaluar el rendimiento y el progreso del modelo de aprendizaje automático.

- **Curva de pérdida de entrenamiento:** La curva de pérdida de entrenamiento muestra cómo disminuye la pérdida del modelo a medida que se realizan más épocas de entrenamiento. Idealmente, esperamos que la pérdida disminuya de manera constante o en una tendencia descendente general. Si la pérdida se mantiene alta o no disminuye significativamente, puede ser un indicio de que el modelo no está aprendiendo adecuadamente o que el conjunto de entrenamiento es demasiado complejo para el modelo. En los cuatro casos el modelo tiene una disminución constante al largo de

las épocas, teniendo una convergencia en un punto donde se estabiliza el valor de la pérdida.

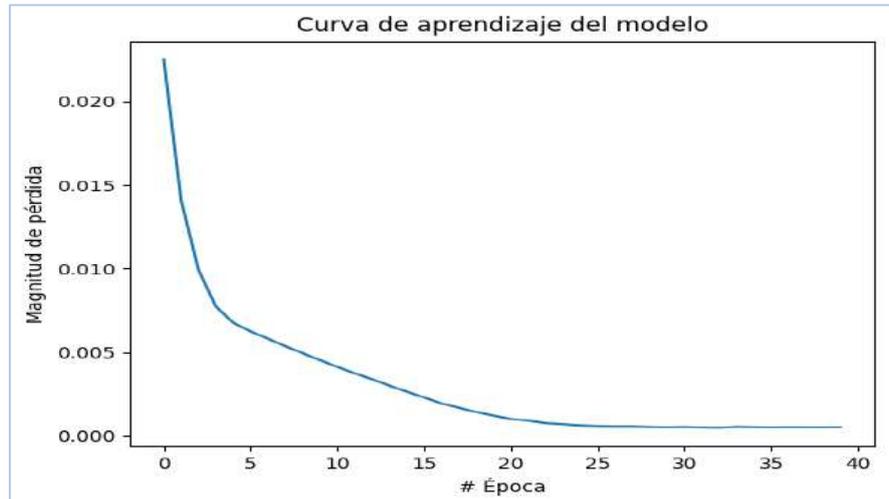
- **Curva de pérdida de validación:** La curva de pérdida de validación ilustra el comportamiento de la pérdida del modelo en un conjunto de datos separados que no se emplean para el entrenamiento. La pérdida de validación es una indicación de la capacidad del modelo para generalizar a datos no vistos con anterioridad. Si la pérdida de validación comienza a aumentar mientras la pérdida de entrenamiento disminuye, es una indicación de que el modelo puede estar superajustando (sobreentrenando) los datos de entrenamiento. En este contexto, es posible que el modelo esté memorizando los ejemplos de entrenamiento en lugar de aprender patrones generales en lugar de aprender patrones generales. En este caso vemos una disminución gradual de la curva de pérdida de validación lo que nos indica que el modelo en las diferentes épocas está aprendiendo patrones y no memorizándolos, con solo 10 épocas vemos una disminución gradual de la curva, pero se puede notar que aun el modelo necesita más épocas de entrenamiento, para 20 épocas ya empieza a estabilizarse en un punto específico, para las 30 épocas vemos el inicio de que la curva sigue un curso constante y para la época 40 ya podemos notar que la curva tiende a estabilizarse y a seguir un curso constante, por lo cual ya no es necesario agregar más épocas de entrenamiento al modelo
- **Diferencia entre las curvas de pérdida:** Es crucial comparar la curva de pérdida de entrenamiento y la curva de pérdida de validación. Si la pérdida de entrenamiento es significativamente menor que la pérdida de validación, esto puede ser un indicativo de sobreajuste. En cambio, si la disminución del entrenamiento y la disminución de la validación se encuentran en una distancia cercana, esto sugiere que el modelo se encuentra generalizando correctamente a datos no vistos. En la época 40, se observa que las curvas son muy cercanas y poseen valores escasos, lo que indica que nuestro modelo se enfoca en la generalización de datos no vistos.

MAGNITUD DE PERDIDA

El objetivo del entrenamiento es minimizar la magnitud de pérdida a medida que el modelo aprende de los datos. Durante el entrenamiento, los pesos y los parámetros del

modelo se ajustan iterativamente para minimizar la magnitud de pérdida y mejorar la precisión de las predicciones. Esto se logra mediante técnicas como el descenso de gradiente, donde la derivada de la magnitud de la pérdida se basa en parámetros y actualizar en dirección opuesta del gradiente para reducirle pérdida.

Gráfico 7. Curva de aprendizaje



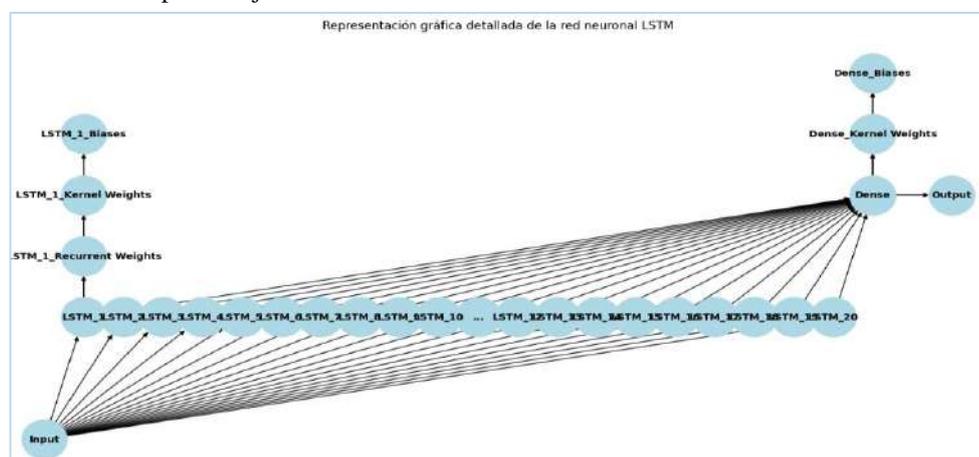
Elaboración: Propia.

El seguimiento de la magnitud de pérdida a lo largo de las épocas puede proporcionar información sobre el rendimiento y el progreso del modelo durante el entrenamiento. Un descenso gradual de la magnitud de pérdida indica que el modelo está mejorando y ajustándose mejor a los datos. Por otro lado, un estancamiento o un aumento en la magnitud de pérdida puede indicar problemas en el modelo o la necesidad de ajustar los parámetros. El modelo muestra un descenso de la magnitud de pérdida gradual lo que nos da buenos indicadores del rendimiento del modelo en 40 épocas de entrenamiento.

ESTIMACIONES DEL MODELO

El modelo está representado de la siguiente manera:

Gráfico 8. Curva de aprendizaje



Elaboración: Propia.

En el gráfico número 7 podemos como está estructurado el modelo estimado, los parámetros internos se describen de la siguiente manera:

1. La entrada (input) alimenta a la capa LSTM.
2. La capa LSTM tiene tres componentes principales:
 - Pesos Recurrentes: Matriz de forma (1, 80) que contiene los pesos de las conexiones recurrentes.
 - Matriz de Pesos Núcleo: Matriz de forma (20, 20) que contiene los pesos de las conexiones entre las entradas y las unidades LSTM.
 - Biases: Vector de forma (80) que contiene los sesgos (biases) de la capa LSTM.
3. Las salidas de la capa LSTM se alimentan a la capa densa.
4. La capa densa consta de:
 - Matriz de Pesos Núcleo: Matriz de forma (20, 1) que contiene los pesos de las conexiones entre las unidades LSTM y la neurona de salida.
 - Bias: Escalar que representa el sesgo (bias) de la capa densa que es un Vector de forma (80).
5. La capa densa combina linealmente las salidas de la capa LSTM utilizando los pesos y el sesgo para producir una salida (input).

Los datos exactos de cada uno de estos parámetros del modelo se pueden ver a detalles en el anexo 06.

Teniendo en consideración la estructura del modelo podemos ver una representación gráfica de las estimaciones del modelo en diferentes épocas de entrenamiento correspondientes a 10, 20, 30 y 40 épocas respectivamente, se puede ver una evolución de las estimaciones, tal y como se esperaba, el modelo responde muy bien reconociendo patrones generales del comportamiento de la variable y hace muy buenas predicciones con datos que desconoce.

Gráfico 9. Datos reales y estimados (10 épocas)



Elaboración: Propia.

En el gráfico 9 podemos ver los datos estimados color rojo, y por otra parte tenemos los datos reales representados con el color negro, visualmente se puede determinar que con 10 épocas de entrenamiento no son suficientes para que el modelo pueda aprender a identificar los patrones de comportamiento de la variable PBI, aun que podemos resaltar que si puede identificar una tendencia creciente de la variable.

Gráfico 10. Datos reales y estimados (20 épocas)



Elaboración: Propia.

En el gráfico 10 podemos ver los datos estimados color rojo, y por otra parte tenemos los datos reales representados con el color negro, visualmente se puede determinar que con 20 épocas de entrenamiento ya se nota un cambio más significativo del modelo, mostrando una tendencia creciente más notoria e identificando los patrones de comportamiento, pero aún no se acercan tanto a los datos reales del PBI.

Gráfico 11. Datos reales y estimados (30 épocas)



Elaboración: Propia.

En el gráfico 11 podemos ver los datos estimados color rojo, y por otra parte tenemos los datos reales representados con el color negro, visualmente se puede determinar que con 30 épocas de entrenamiento se muestra estimaciones muy cercadas a los datos reales, especialmente en la en todo el periodo de 1980 a 2010 esto se debe a que el modelo conoce estos datos y fueron entrenados con estos, mientras que con los datos posteriores a estos el modelo también identifica la tendencia y el comportamiento de la variable pero con menos precisión.

Gráfico 12. Datos reales y estimados (40 épocas)



Elaboración: Propia.

En el gráfico 12 podemos ver los datos estimados color rojo, y por otra parte tenemos los datos reales representados con el color negro, visualmente se puede determinar que con 40 épocas de entrenamiento se muestra estimaciones muy cercadas a los datos reales, especialmente con los datos que el modelo fue entrenado y con los datos que no conoce, correspondientes a las predicciones del modelo, pudo identificar las tendencias e identificar los patrones de comportamiento con mucha eficiencia.

Las gráficas mostradas nos dan los resultados de como el modelo aprende según el tiempo de entrenamiento (épocas) que se le da, pues al inicio se nota que unas estimaciones muy poco precisas y posteriormente, al aumentar las épocas de entrenamiento se puede ver una mejora significativa en las estimaciones tanto con datos que el modelo conoce y con datos que el modelo desconoce, mostrando la eficacia de la red neuronal para identificar patrones y comportamiento de variables económicas y hacer predicciones de estas.

PRUEBAS ESTADISTICAS

Las redes neuronales LSTM (Long Short-Term Memory) son modelos de aprendizaje automático que se utilizan comúnmente para problemas de series temporales y secuencias. A diferencia de los modelos lineales, las redes neuronales LSTM no se basan en supuestos específicos sobre los datos. En cambio, su enfoque principal es aprender patrones y relaciones complejas de manera automática a partir de los datos.

Los supuestos de no autocorrelación, homocedasticidad y normalidad de los residuos son más comúnmente aplicables a los modelos lineales, como la regresión lineal, que se basan en supuestos específicos sobre la estructura y distribución de los datos. Sin embargo, para las redes neuronales LSTM, algunos de estos supuestos pueden no ser tan relevantes o pueden requerir enfoques diferentes.

No autocorrelación: Este supuesto asume que los residuos del modelo no muestran correlación serial, es decir, no hay patrones sistemáticos en los residuos a lo largo del tiempo. En las redes neuronales LSTM, este supuesto puede ser menos relevante ya que estos modelos están diseñados para capturar patrones secuenciales en los datos, incluida la autocorrelación. Sin embargo, si se observa una autocorrelación significativa en los residuos de la red LSTM, se pueden tomar medidas para abordarla, como el ajuste del modelo, la incorporación de variables de retardo, el uso de técnicas de regularización o la aplicación de modelos de series temporales específicos.

Homocedasticidad: Este supuesto implica que la varianza de los residuos es constante en todas las observaciones y no muestra patrones sistemáticos en función de las variables independientes o las predicciones del modelo. En las redes neuronales LSTM, no se asume necesariamente la homocedasticidad, ya que estos modelos pueden ser capaces de capturar relaciones no lineales y variaciones heterocedásticas en los datos.

Multicolinealidad: Este supuesto se refiere a la correlación alta o perfecta entre las variables independientes en un modelo lineal. En las redes neuronales LSTM, la multicolinealidad puede no ser un problema importante, ya que estas redes pueden aprender automáticamente las relaciones complejas entre las variables de entrada, incluso

si hay cierta correlación entre ellas. Sin embargo, es recomendable realizar un análisis de correlación entre las variables de entrada para identificar cualquier multicolinealidad fuerte que pueda afectar el rendimiento del modelo. Si se detecta multicolinealidad significativa, se pueden aplicar técnicas de selección de características, reducción de dimensionalidad o regularización para abordar este problema.

Normalidad de los residuos: las redes neuronales LSTM no requieren que los residuos sigan el supuesto de normalidad. Los supuestos de normalidad de los residuos son más comunes en modelos lineales clásicos, como la regresión lineal. Sin embargo, las redes neuronales LSTM son modelos no lineales y no se basan en los mismos supuestos.

Las redes neuronales LSTM son especialmente útiles para modelar relaciones complejas y no lineales en conjuntos de datos, como series temporales. Estas redes tienen la capacidad de capturar patrones temporales y dependencias a largo plazo en los datos.

A pesar de que los supuestos de autocorrelación, homocedasticidad, multicolinealidad y normalidad de los residuos son relevantes en los modelos lineales, las redes neuronales LSTM pueden requerir enfoques distintos o no ser tan críticos debido a la habilidad de estas redes para capturar patrones secuenciales y relaciones no lineales en los datos. No obstante, resulta imperativo examinar y abordar cualquier violación significativa de estos supuestos que pudiera afectar el rendimiento del modelo.

Sin embargo, hay ciertos aspectos para tener en cuenta al utilizar redes neuronales LSTM:

Datos suficientes: Es esencial disponer de un conjunto de datos lo bastante amplio para entrenar una red neuronal LSTM de manera eficaz. Esto contribuye a prevenir el sobreajuste y a mejorar la generalización del modelo.

Preprocesamiento de datos: Antes de entrenar una red neuronal LSTM, es habitual llevar a cabo un preprocesamiento adecuado de los datos. Esto puede requerir la normalización de las características, la codificación adecuada de las variables categóricas, la eliminación de valores atípicos, el manejo de valores faltantes, etc.

Elección de arquitectura: La selección de la arquitectura de la red neuronal LSTM, tales como el número de capas, el número de unidades en cada capa, la función de activación, etc., puede influir en el rendimiento del modelo. Es necesario llevar a cabo pruebas y ajustes con el fin de obtener una configuración adecuada.

Evaluación y validación: Es de suma importancia evaluar el rendimiento del modelo mediante la utilización de métricas apropiadas, tales como el error cuadrático medio (MSE), el coeficiente de determinación (R^2), la precisión, el recuerdo, entre otras.

Asimismo, es necesario llevar a cabo una validación cruzada o separación de conjuntos de entrenamiento, validación y prueba con el fin de evaluar el rendimiento del modelo en datos no visibles.

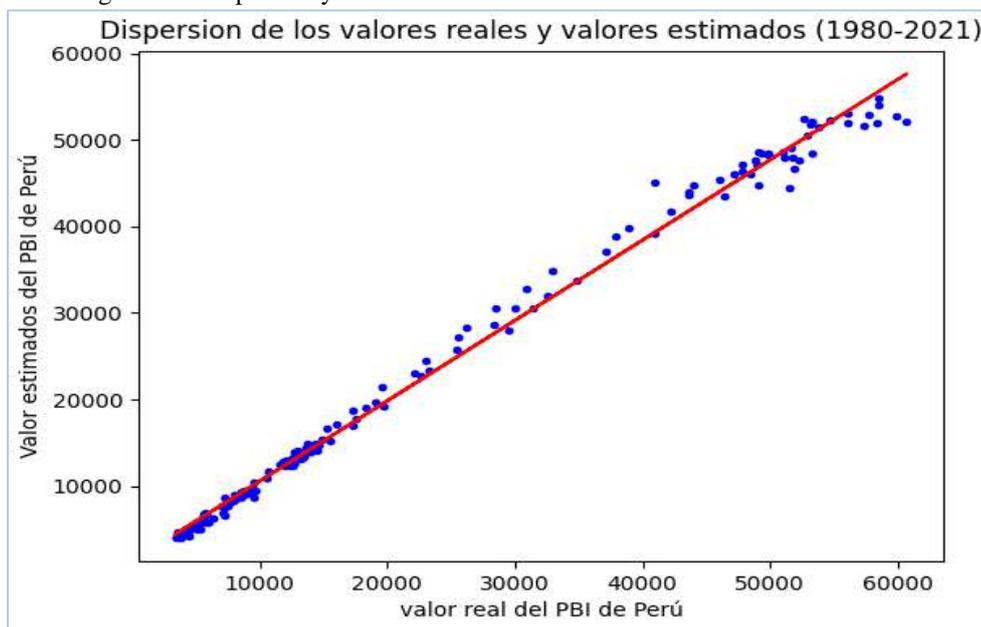
EL COEFICIENTE DE DETERMINACIÓN PARA TODOS LOS DATOS (R^2)

Para el cálculo del coeficiente de determinación nos hemos apoyado del lenguaje de programación Python, el cual nos facilita el desarrollo de matemático y estadístico debido a la complejidad del modelo, los resultados se muestran a continuación:

$$R^2 = 0.9879977774702624$$

El R^2 mide directamente qué proporción de la variabilidad en los datos reales es capturada por las predicciones del modelo, proporcionando una evaluación más directa de la capacidad predictiva del modelo, en esos términos podemos decir que un 98.79% variabilidad en los datos reales es capturada por las predicciones del modelo. Además del cálculo tradicional del coeficiente de determinación R^2 , hemos explorado un enfoque alternativo para evaluar la precisión del modelo. Este enfoque implica realizar una regresión lineal entre las predicciones del modelo y los valores reales del PBI, y evaluar qué tan bien se alinean estos puntos a lo largo de una línea de tendencia.

Gráfico 13. Diagrama de dispersión y línea de tendencia



Elaboración: Propia.

En el gráfico 13 podemos ver que los datos tienen una mínima dispersión y siguen una tendencia lineal casi perfecta, mediante los cálculos realizados mediante Python se tienen los siguientes datos:

Tabla 6. Coeficiente de determinación

Coeficiente (pendiente)	0.92101776
Intersección:	1498.29016519
Coeficiente de determinación R^2 (COMPORTAMIENTO Y PREDICIÓN)	0.9935058935433656

Elaboración: Propia.

Este coeficiente de determinación indica que aproximadamente el 99.35% de la variabilidad en los datos se explica por el modelo de regresión, lo que sugiere que el modelo de regresión lineal ajusta muy bien a los datos.

EL COEFICIENTE DE DETERMINACIÓN (R^2) PARA DATOS QUE EL MODELO CONOCE

Representamos gráficamente los datos reales y estimados, los datos reales corresponden a los datos de entrenamiento del modelo, datos que el modelo conoce.

Gráfico 14. Datos reales y estimados (datos conocidos)



Elaboración: Propia.

En el gráfico 14 se puede ver el comportamiento de la variable analizada junto con la estimación de esta con el modelo entrenado, se puede ver que las estimaciones son muy cercadas a los datos reales ya que el modelo fue entrenado y validado con estos datos.

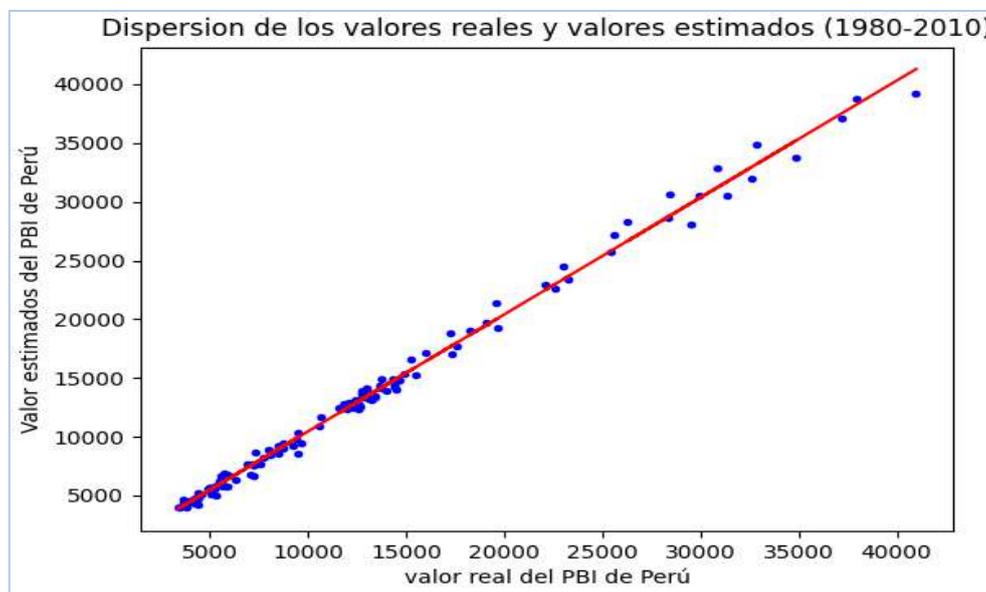
Se estima el coeficiente de determinación para los datos que el modelo conoce, se presenta el resultado a continuación:

$$R^2 = 0.9896478264098069$$

Se puede determinar que 98.96% variabilidad en los datos reales es capturada por las predicciones del modelo, de igual forma que el análisis general hecho anteriormente

aplicamos un enfoque alternativo que implica una regresión lineal entre las predicciones del modelo y los valores reales del PBI, y evaluar qué tan bien se alinean estos puntos a lo largo de una línea de tendencia.

Gráfico 15. Diagrama de dispersión datos reales y estimados (datos conocidos)



Elaboración: Propia.

En el gráfico 15 podemos ver que los tiene una mínima dispersión y siguen una tendencia de lineal casi perfecta, mediante los cálculos realizados mediante Python se tiene los siguientes datos:

Tabla 7. Coeficiente de determinación

Coeficiente (pendiente)	0.9961435
Intersección:	608.9666452
Coeficiente de determinación R^2 (COMPORTAMIENTO Y PREDICIÓN)	0.9939649330292343

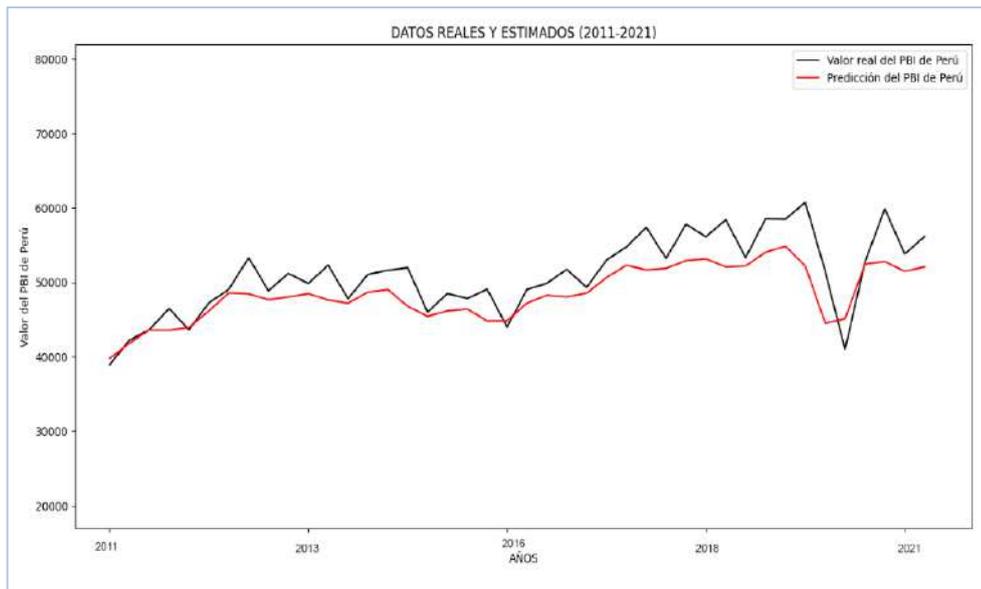
Elaboración: Propia.

Este coeficiente de determinación indica que aproximadamente el 99.39% de la variabilidad en los datos se explica por el modelo de regresión, lo que sugiere que el modelo de regresión lineal ajusta muy bien a los datos.

EL COEFICIENTE DE DETERMINACIÓN (R^2) PARA DATOS QUE EL MODELO DESCONOCE

Representamos gráficamente los datos reales y estimados, los datos reales corresponden a los datos que el modelo no conoce.

Gráfico 16. Datos reales y estimados (datos no conocidos)



Elaboración: Propia.

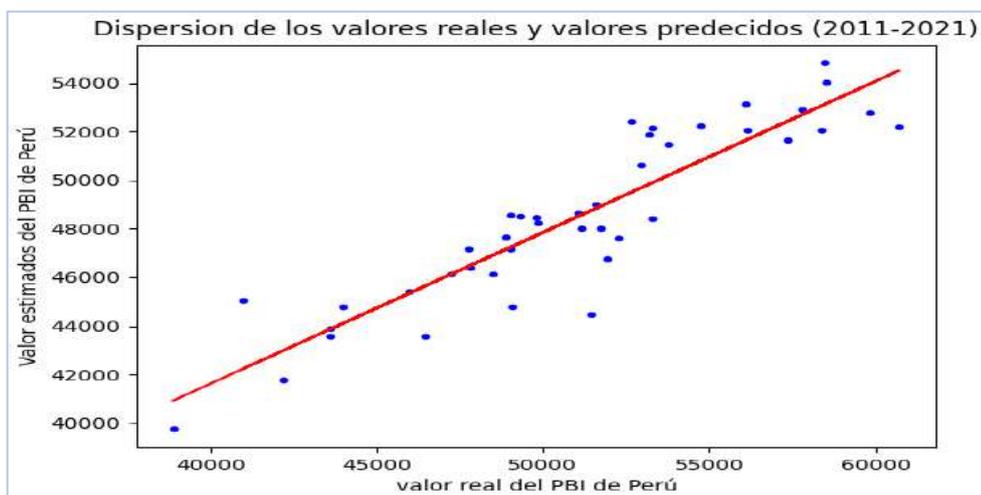
En el gráfico 16 se puede ver el comportamiento de la variable analizada junto con la estimación de esta con el modelo entrenado, se puede ver que las estimaciones son muy cercadas a los datos reales ya que el modelo fue entrenado y validado con estos datos.

Se estima el coeficiente de determinación para los datos que el modelo conoce, se presenta el resultado a continuación:

$$R^2 = 0.7662001599756935$$

Se puede determinar que 76.62% variabilidad en los datos reales es capturada por las predicciones del modelo, de igual forma que el análisis general hecho anteriormente aplicamos un enfoque alternativo que implica una regresión lineal entre las predicciones del modelo y los valores reales del PBI, y evaluar qué tan bien se alinean estos puntos a lo largo de una línea de tendencia.

Gráfico 17. Diagrama de dispersión datos reales y estimados (datos no conocidos)



Elaboración: Propia.

En el gráfico 17 podemos ver que los tiene una mínima dispersión y siguen una tendencia de lineal casi perfecta, mediante los cálculos realizados mediante Python se tiene los siguientes datos:

Tabla 8. Coeficiente de determinación

Coeficiente (pendiente)	0.68535085
Intersección:	15429.22034249
Coeficiente de determinación R ² (COMPORTAMIENTO Y PREDICIÓN)	0.7950939427689112

Elaboración: Propia.

Este coeficiente de determinación indica que aproximadamente el 68.53% de la variabilidad en los datos se explica por el modelo de regresión, lo que sugiere que el modelo de regresión lineal ajusta muy bien a los datos.

Contrastación de hipótesis

Planteamiento de las hipótesis nulas y alternas

Prosiguiendo plantearemos las hipótesis:

Hipótesis General.

H0: No existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021.

H1: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021.

Hipótesis Específico 1 (HE1).

H0: No Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento de los datos del PBI:1980 - 2010.

H1: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento de los datos del PBI:1980 - 2010.

Hipótesis Específico 2 (HE2).

H0: No Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis de la predicción de los datos del PBI de Perú: 2011 – 2021.

H1: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis de la predicción de los datos del PBI de Perú: 2011 – 2021.

Elección del umbral de confianza estadística

Generalmente, se considera apropiado utilizar un umbral de confianza estadística (representado por alfa) del 0,05. Este valor implica que existe una probabilidad del 5%

de afirmar erróneamente la existencia de una diferencia cuando en realidad no la hay. Teniendo esto en cuenta, en nuestro estudio se decidió emplear un umbral de confianza del 5%, ya que se consideró que proporcionaba un equilibrio adecuado entre rigor estadístico y sensibilidad en la detección de diferencias significativas

Selección del método estadístico apropiado.

En el contexto de nuestra investigación, basándonos en los datos recopilados, hemos concluido que, para evaluar la validez de la hipótesis nula, es apropiado emplear la prueba de distribución normal, también conocido como distribución Z. Esta elección se justifica por el hecho de que estamos trabajando con una muestra de gran tamaño y conocemos la desviación estándar de la población. Consecuentemente, el valor estadístico para nuestro análisis se calculará utilizando la fórmula correspondiente a esta distribución.

$$z_c = \frac{\bar{x} - M}{\left(\frac{\sigma}{\sqrt{n}}\right)}$$

DONDE:

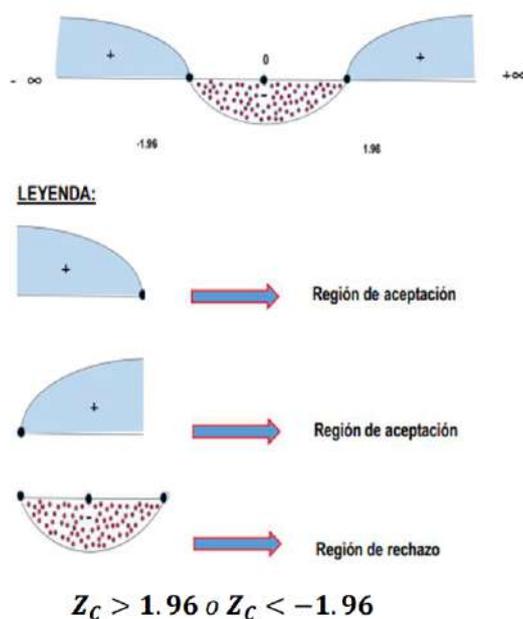
Z= Distribución normal

\bar{x} = Media poblacional

μ = Estimador puntual

σ = Desviación típica

n = número de observaciones



$Z_c > Z_T$: Se rechaza la hipótesis nula y se acepta la alterna

Dónde:

z_C : La distribución normal calculada.

z_T : La distribución normal de tabla.

Estimación de decisión.

Realizamos el análisis correspondiente para determinar si aceptamos la H_0 o se rechaza la H_0 .

Hipótesis General.

$$z_T = 1.96$$

$$H_0: R^2 < 0.9879$$

$$H_1: R^2 \geq 0.9879$$

Se tiene que:

$$\bar{x} = 22827.721099$$

$$R^2 = 0.9879$$

$$\sigma = 18694.976637$$

$$n = 168$$

$$z_C = \frac{\bar{x} - R^2}{\left(\frac{\sigma}{\sqrt{n}}\right)}$$

$$z_C = 15.82609266596192$$

Se observa que: $z_C > z_T$; Es decir se rechaza la hipótesis nula y se acepta la hipótesis

Hipótesis Específico 1 (HE1).

$$H_0: R^2 < 0.98964$$

$$z_T = 1.96$$

$$H_1: R^2 \geq 0.98964$$

Se tiene que:

$$\bar{x} = 12742.822622$$

$$R^2 = 0.98964$$

$$\sigma = 8559.604486$$

$$n = 124$$

$$z_C = \frac{\bar{x} - R^2}{\left(\frac{\sigma}{\sqrt{n}}\right)}$$

$$z_C = 16.57636887196221$$

Se observa que: $z_C > z_T$; Es decir se rechaza la hipótesis nula y se acepta la hipótesis

Hipótesis Específico 2 (HE2).

$$H_0: R^2 < 0.7662$$

$$z_T = 1.96$$

$$H_1: R^2 \geq 0.7662$$

Se tiene que:

$$\bar{x} = 51248.798625$$

$$R^2 = 0.7662$$

$$\sigma = 5287.679511$$

$$n = 44$$

$$z_C = \frac{\bar{x} - R^2}{\left(\frac{\sigma}{\sqrt{n}}\right)}$$

$$z_C = 64.28948221082456$$

Se observa que: $z_C > z_T$; Es decir se rechaza la hipótesis nula y se acepta la hipótesis.

5.3. Discusión de resultados

El proceso de entrenamiento del modelo para predecir el PBI de Perú se realizó mediante cuatro configuraciones de épocas diferentes: 10, 20, 30 y 40. A continuación se presenta un análisis minucioso del rendimiento del modelo durante este proceso.

Durante el entrenamiento, se llevó a cabo un seguimiento minucioso de la evolución de la curva de pérdida, tanto en los datos de entrenamiento como en los datos de validación. La curva de pérdida de entrenamiento exhibe una disminución gradual y constante a medida que se incrementan las épocas. Este patrón indica que el modelo está adquiriendo de manera efectiva los patrones presentes en los datos de entrenamiento, lo cual resulta crucial para su capacidad predictiva.

El procedimiento de entrenamiento del modelo para predecir el PBI de Perú se llevó a cabo mediante cuatro configuraciones de épocas distintas: 10, 20, 30, y 40. A continuación se presenta una evaluación minuciosa del desempeño del modelo durante este procedimiento.

Durante el entrenamiento, se llevó a cabo un análisis minucioso de la evolución de la curva de pérdida, tanto en los datos de entrenamiento como en los datos de validación. La curva de pérdida de entrenamiento presenta una disminución gradual y constante a medida que aumentan las épocas. Este patrón indica que el modelo está adquiriendo de manera eficaz los patrones presentes en los datos de entrenamiento, lo cual resulta esencial para su capacidad predictiva.

Además, la magnitud de pérdida muestra una disminución gradual a medida que avanza el entrenamiento. Este descenso en la pérdida es crucial, ya que indica que el modelo está ajustando sus parámetros de manera efectiva para minimizar errores y mejorar la precisión de las predicciones.

En el análisis del modelo predictivo para el PBI de Perú, hemos calculado y evaluado el coeficiente de determinación (R^2) bajo diferentes contextos: para todos los datos, para los datos que el modelo conoce y para los datos que el modelo no conoce. Este análisis nos proporciona una visión clara de la capacidad del modelo para capturar la variabilidad en los datos reales y su rendimiento predictivo en diferentes escenarios.

Coeficiente de Determinación para Todos los Datos

El coeficiente de determinación (R^2) calculado para todos los datos es de 0.9879977774702624, lo que indica que el modelo es capaz de capturar el 98.79% de la variabilidad en los datos reales. Este valor sugiere una alta capacidad predictiva del modelo, ya que un (R^2) cercano a 1 implica que las predicciones del modelo se alinean muy bien con los datos observados. Además, un análisis adicional mediante regresión lineal entre las predicciones del modelo y los valores reales del PBI mostró un coeficiente (R^2) de 0.9935058935433656, reforzando la idea de un excelente ajuste del modelo a los datos.

Coeficiente de Determinación para Datos que el Modelo Conoce

Al evaluar el modelo con los datos que el modelo ha visto durante el entrenamiento, el coeficiente de determinación (R^2) es de 0.9896478264098069. Este resultado es consistente con el análisis anterior, indicando que el 98.96% de la variabilidad en los datos de entrenamiento es capturada por el modelo. Este alto valor de (R^2) es esperable, ya que el modelo ha sido ajustado específicamente para estos datos. La regresión lineal entre las predicciones y los valores reales para estos datos arroja un coeficiente (R^2) de 0.9939649330292343, sugiriendo nuevamente un ajuste casi perfecto.

Coeficiente de Determinación para Datos que el Modelo Desconoce

La evaluación del modelo con datos no conocidos durante el entrenamiento proporciona un coeficiente de determinación (R^2) de 0.7662001599756935, indicando que el modelo puede explicar el 76.62% de la variabilidad en los datos no conocidos. Este valor, aunque menor que los obtenidos con los datos de entrenamiento, sigue siendo razonablemente alto y sugiere que el modelo mantiene una capacidad predictiva significativa fuera de su conjunto de entrenamiento. La regresión lineal aplicada en este contexto arroja un (R^2)

de 0.7950939427689112, lo que también indica un buen ajuste, aunque con menor precisión comparada con los datos conocidos.

Análisis y Comparación

Los resultados obtenidos muestran que el modelo tiene una excelente capacidad predictiva para los datos de entrenamiento y una buena capacidad predictiva para los datos fuera de muestra. La ligera disminución en el coeficiente (R^2) para los datos no conocidos es común y refleja la dificultad de predecir con exactitud datos que el modelo no ha visto antes. No obstante, un (R^2) superior a 0.75 sigue siendo indicativo de un modelo robusto y confiable.

La alta correlación lineal observada en los diagramas de dispersión y los valores de (R^2) cercanos a 1 en los enfoques alternativos refuerzan la conclusión de que el modelo ajusta bien a los datos y es capaz de capturar la mayor parte de la variabilidad en el PBI de Perú. Esto sugiere que el modelo puede ser utilizado con confianza para realizar predicciones y análisis de tendencias en el PBI de Perú.

El análisis del coeficiente de determinación bajo diferentes contextos confirma la solidez del modelo predictivo desarrollado, demostrando su alta capacidad para capturar la variabilidad en los datos reales del PBI de Perú, tanto en el conjunto de entrenamiento como en los datos no conocidos. Este desempeño destaca la utilidad del modelo en aplicaciones prácticas y en la toma de decisiones basada en datos económicos.

CONCLUSIONES

En relación con el objetivo general, los resultados indican que el modelo de redes neuronales es altamente eficiente tanto en el análisis del comportamiento histórico como en la predicción del PBI de Perú para el periodo 1980-2021. El modelo alcanzó un R^2 de 0.9879, lo que sugiere que el 98.79% de la variabilidad en el PBI durante este periodo es explicada por el modelo. Este valor cercano a 1 indica que el modelo de redes neuronales se ajusta excepcionalmente bien a los datos observados del PBI de Perú, replicando de manera precisa las variaciones históricas y proporcionando predicciones confiables.

En relación con el objetivo específico uno, los resultados indican que el modelo de redes neuronales utilizado es altamente eficiente para analizar el comportamiento histórico del PBI de Perú en el periodo 1980-2010. Esto se evidencia por un R^2 de 0.9896, lo que implica que el 98.96% de la variabilidad en el PBI durante este periodo es explicada por el modelo. Este alto valor de R^2 demuestra la capacidad del modelo para capturar las tendencias y patrones históricos del PBI, lo que sugiere una fuerte precisión en sus predicciones y análisis.

En cuanto al objetivo específico dos, los resultados indican que el modelo de redes neuronales es eficiente para analizar el comportamiento del PBI de Perú en el periodo 2010-2021, en lo que respecta al objetivo específico dos. Al aplicar el modelo a datos no utilizados durante el entrenamiento, se obtuvo un R^2 de 0.7662 al aplicar el modelo a datos no utilizados durante el entrenamiento, lo que significa que el 76.62% de la variabilidad en el PBI durante este periodo se explica por el modelo. Aunque el modelo tiene una buena capacidad para capturar las tendencias y patrones del PBI, existe margen para mejorar su precisión en predicciones con datos fuera de la muestra de entrenamiento.

RECOMENDACIONES

Validación y Actualización Continua del Modelo: Dado que el modelo de redes neuronales demostró una alta eficiencia en el análisis y predicción del PBI de Perú, es recomendable continuar validando y actualizando el modelo con datos más recientes a medida que estén disponibles. Esto ayudará a mantener la precisión del modelo y a adaptarse a posibles cambios en el comportamiento económico.

Segmentación de Datos: Considera segmentar los datos en períodos de tiempo específicos, como se hizo en los objetivos específicos uno y dos. Esto puede ayudar a identificar patrones de comportamiento más precisos dentro de cada período y mejorar la capacidad predictiva del modelo para cada segmento de tiempo.

Inclusión de Variables Adicionales: Aunque el modelo de redes neuronales fue altamente eficiente en el análisis del PBI utilizando los datos disponibles, considera la posibilidad de incluir variables adicionales que puedan influir en el comportamiento económico. Esto podría mejorar aún más la precisión de las predicciones y proporcionar una comprensión más completa de los factores que afectan al PBI peruano.

REFERENCIAS BIBLIOGRÁFICAS

- Arrieta, J., Torres, J., & Velásquez, H. (2009). PREDICCIONES DE MODELOS ECONOMÉTRICOS Y REDES NEURONALES: EL CASO DE LA ACCIÓN DE SURAMINV*. *Semestre Económico - Universidad de Medellín*, 95-109. Obtenido de <http://www.scielo.org.co/pdf/seec/v12n25/v12n25a7.pdf>
- Arturo, E., Hernan, J., & Medina, P. (Mayo de 2009). PRONOSTICO DEL INDICE GENERAL DE LA BOLSA DE VALORES DE COLOMBIA USANDO REDES NEURONALES. *Scientia et Technica Año XV*, 129-134. Obtenido de <https://revistas.utp.edu.co/index.php/revistaciencia/article/view/2889/1603>
- Basogain, X. (s.f.). *REDES NEURONALES ARTIFICIALES Y SUS APLICACIONES*. Bilbao. Obtenido de https://d1wqtxts1xzle7.cloudfront.net/38647082/libro-Redes_neuronaes-with-cover-page-v2.pdf?Expires=1654525894&Signature=AX01kfSDXOmpPgShYTUrbUE5WJ-M6ZLYc~Qs~j66uaSmWv~1uVGirb-yE0WuI4AggSn4lnJxRdNJVatvyYfHL664rPoDoIQBYG6aBpa2yjHcH62U57F-mwbfVR4ajwmLekD-p9
- Byrd, S. (Abril de 1998). *APLICACIÓN DE REDES NEURONALES PARA DESARROLLAR UN MODELO DE PRONÓSTICO DE LA DEMANDA DE DINERO*. Obtenido de INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE MONTERREY: <https://repositorio.tec.mx/bitstream/handle/11285/628356/CEM108564.pdf?sequence=1&isAllowed=y>

- Ceular, N., & Caridad y Ocerín, J. (Agosto de 2001). Un análisis del mercado de la vivienda a través de redes neuronales artificiales. *Estudios de Economía Aplicada*, 41-66. Obtenido de <https://www.redalyc.org/pdf/301/30118210.pdf>
- IBM. (2018). *¿Qué es Machine Learning?* Obtenido de <https://www.ibm.com/pe-es/analytics/machine-learning>
- IBM. (17 de 08 de 2021). *El modelo de redes neuronales*. Obtenido de <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
- McCarthy, J. (12 de 11 de 2007). *Universidad de Leeds, Universidad Macquarie*. Obtenido de <http://www-formal.stanford.edu/jmc/whatisai/>
- Ministerio de Economía y Finanzas. (Febrero de 2024). *¿Qué es el Producto Bruto Interno?* Obtenido de https://www.mef.gob.pe/es/?option=com_content&language=es-ES&Itemid=100694&view=article&catid=23&id=61&lang=es-ES
- Saenz, J. M. (Mayo de 2009). EVALUACION DE PRONOSTICO DE UNA RED NEURONAL SOBRE EL PIB EN COLOMBIA. *PONTIFICA UNIVERSIDAD JAVERIANA*, 29-30. Obtenido de <https://201.131.90.33/index.php/revistaciencia/article/view/6539/3761>

ANEXOS

ANEXO 01
MATRIZ DE CONSISTENCIA

MATRIZ DE CONSISTENCIA

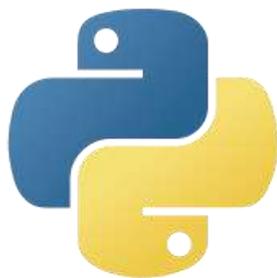
TITULO: Modelo de redes neuronales artificiales en análisis del comportamiento y predicción PBI en el Perú: 1980-2021.

PROBLEMA	OBJETIVOS	HIPOTESIS	OPERACIONALIZACIÓN DE LAS VARIABLES			DEFINICIÓN OPERACIONAL	METODOLOGIA
			VARIABLES DE ESTUDIO	DIMENSIONES	UNIDAD DE MEDIDA		
<p>Problema General. PG: ¿En medida la aplicación del modelo de redes neuronales resulta efectivo con el análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021?</p> <p>Problemas Específicos. PE1: ¿De qué forma la aplicación del modelo de redes neuronales resulta efectivo con el análisis del comportamiento del PBI de Perú: 1980 - 2010? PE2: ¿De qué forma la aplicación del modelo de redes neuronales resulta efectivo con el análisis de la predicción del PBI de Perú 2011 - 2021?</p>	<p>Objetivo General. OG: Evaluar el nivel de efectividad del modelo de redes neuronales con relación al análisis del comportamiento y predicción del PBI de Perú:1980 - 2021.</p> <p>Objetivos Específicos. OE1: Estimar el R² para evaluar el nivel de efectividad del modelo de redes neuronales con relación al análisis del comportamiento del PBI de Perú: 1980 – 2010. OE2: Estimar el R² para evaluar el nivel de efectividad del modelo de redes neuronales en el análisis predicciones el PBI del Perú: 2011 – 2021.</p>	<p>Hipótesis General: HG: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento y predicción del PBI de Perú: 1980 - 2021.</p> <p>Hipótesis Específicas: HE1: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis del comportamiento de los datos del PBI:1980 – 2010. HE2: Existe altos niveles de efectividad en la aplicación del modelo de redes neuronales para el análisis de la predicción de los datos del PBI de Perú: 2011 - 2021.</p>	PBI de Perú	PBI Trimestral Perú (US\$ millones).	MILES DE MILLONES DE DOLARES	Es una medida de crecimiento de una economía o país	<p>Tipo: Aplicada Diseño: No experimental Nivel: Descriptivo</p>

ANEXO 02

INSTRUMENTO (SOFTWARE DE PROGRAMACION

- Python versión 3.12.3



python™

Enlace: <https://www.python.org/downloads/>

- Visual studio code

A screenshot of the Visual Studio Code editor interface. The main window displays a Python script with several functions for data analysis and visualization. The code includes imports for libraries like numpy, pandas, matplotlib, and sklearn. It defines functions for data loading, preprocessing, and model training. The code is written in a dark theme with syntax highlighting. The left sidebar shows the Explorer view with a file named 'script.py' selected. The bottom status bar indicates the current file is 'script.py' and the Python version is '3.12.3'.

Enlace: <https://code.visualstudio.com/Download>

ANEXO 03

INSTRUMENTOS DE VALIDACION



UNIVERSIDAD NACIONAL HERMILIO VALDIZAN
HUANUCO – PERU
FACULTAD DE ECONOMÍA



VALIDACIÓN DE INSTRUMENTO

NOMBRE DEL EXPERTO: Roberto Angelo Calero Bravo

ESPECIALIDAD: Magister en Economía.

TESISTA: Alvarez Flores, Jhon Harrinson; Enriquez Montes, Christian Jhon y Tineo Cruz, Rafaela Carolina

TÍTULO: “NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980 – 2021”

TABLA DE INSTRUMENTO DE RECOLECCION DE DATOS

Date	TRIMESTRE - AÑO	PBI US\$
30/03/1980	T1-80	-
.	.	.
.	.	.
.	.	.
30/06/2010	T2-10	-
.	.	.
.	.	.
.	.	.
30/12/2021	T4-21	-

“Calificar con 1,2,3, o 4 cada ítem respecto a los criterios de relevancia, coherencia suficiencia y claridad”

RELEVANCIA	4
COHERENCIA	4
SUFICIENCIA	4
CLARIDAD	4

DECISION DEL EXPERTO:

El instrumento debe ser aplicado: SI (x) NO ()

Roberto Angelo Calero Bravo



UNIVERSIDAD NACIONAL HERMILIO VALDIZAN
HUANUCO – PERU
FACULTAD DE ECONOMÍA



VALIDACIÓN DE INSTRUMENTO

NOMBRE DEL EXPERTO: Jeel Elvis Cueva Laguna

ESPECIALIDAD: MAESTRO EN EDUCACIÓN, MENCIÓN: INVESTIGACIÓN Y DOCENCIA SUPERIOR

TESISTA: Alvarez Flores, Jhon Harrinson; Enriquez Montes, Crhistian Jhon y Tineo Cruz, Rafaela Carolina

TÍTULO: “NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980 – 2021”

TABLA DE INSTRUMENTO DE RECOLECCION DE DATOS

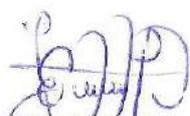
Date	TRIMESTRE - AÑO	PBI US\$
30/03/1980	T1-80	-
.	.	.
.	.	.
30/06/2010	T2-10	-
.	.	.
.	.	.
30/12/2021	T4-21	-

“Calificar con 1,2,3, o 4 cada ítem respecto a los criterios de relevancia, coherencia suficiencia y claridad”

RELEVANCIA	4
COHERENCIA	4
SUFICIENCIA	4
CLARIDAD	4

DECISION DEL EXPERTO:

El instrumento debe ser aplicado: SI (x) NO ()



 Mr. Jeel Elvis Cueva Laguna, Jeel Eln
 ECONOMISTA
 C.E.M. N° 0725



UNIVERSIDAD NACIONAL HERMILIO VALDIZAN
HUANUCO - PERU
FACULTAD DE ECONOMÍA



VALIDACIÓN DE INSTRUMENTO

NOMBRE DEL EXPERTO: Miguel Bryan Naraez del Aguila

ESPECIALIDAD: Magister en Gestión Pública para el Desarrollo Social

TESISTA: Alvarez Flores, Jhon Harrinson; Enriquez Montes, Crhistian Jhon y Tineo Cruz, Rafaela Carolina

TÍTULO: “NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980 – 2021”

TABLA DE INSTRUMENTO DE RECOLECCION DE DATOS

Date	TRIMESTRE - AÑO	PBI US\$
30/03/1980	T1-80	-
.	.	.
.	.	.
.	.	.
30/06/2010	T2-10	-
.	.	.
.	.	.
.	.	.
30/12/2021	T4-21	-

“Calificar con 1,2,3, o 4 cada ítem respecto a los criterios de relevancia, coherencia suficiencia y claridad”

RELEVANCIA	4
COHERENCIA	4
SUFICIENCIA	4
CLARIDAD	4

DECISION DEL EXPERTO:

El instrumento debe ser aplicado: SI (X) NO ()

ECON. Miguel Bryan Naraez del Aguila



UNIVERSIDAD NACIONAL HERMILO VALDIZAN
HUANUCO - PERU
FACULTAD DE ECONOMÍA



VALIDACIÓN DE INSTRUMENTO

NOMBRE DEL EXPERTO: Abilio Vicente Carhuas

ESPECIALIDAD: Especialista en Proyectos

TESISTA: Alvarez Flores, Jhon Harrinson; Enriquez Montes, Crhstian Jhon y Tineo Cruz, Rafaela Carolina

TÍTULO: "NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980 - 2021"

TABLA DE INSTRUMENTO DE RECOLECCION DE DATOS

Date	TRIMESTRE - AÑO	PBI US\$
30/03/1980	T1-80	-
.	.	.
.	.	.
30/06/2010	T2-10	-
.	.	.
.	.	.
30/12/2021	T4-21	-

"Calificar con 1,2,3, o 4 cada ítem respecto a los criterios de relevancia, coherencia suficiencia y claridad"

RELEVANCIA	4
COHERENCIA	4
SUFICIENCIA	4
CLARIDAD	4

DECISION DEL EXPERTO:

El instrumento debe ser aplicado: SI (x) NO ()


 Econ. ABILIO VICENTE CARHUAS
 REG. CENCO N° 271

ANEXO 04
OTROS
FICHA DE RECOLECCIÓN DE DATOS

Registro de del PBI trimestral de Perú desde 1980 - 2021

Date	TRIMESTRE - AÑO	PBI US\$ (Millones)
30/03/1980	T1-80	-
.	.	.
.	.	.
.	.	.
30/06/1990	T2-90	-
.	.	.
.	.	.
.	.	.
30/09/2000	T3-00	-
.	.	.
.	.	.
.	.	.
30/03/2010	T1-10	-
.	.	.
.	.	.
.	.	.
30/12/2021	T4-21	-

Elaboración: propia.

CODIGO EN PYTHON

```

codigo tesis.py 9+ X
C: > Users > jhalv > OneDrive > Escritorio > Nueva carpeta > BORRADOR DE TESIS > codigo tesis.py > graficar_todo
1  """MODELO DE REDES NEURONALES ARTIFICIALES PBI PERU"""
2  """EN EL ANALISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI EN
3  PERU PRIMER TRIMESTRE DE 1980 HASTA EL CUARTO TRIMESTRE DEL 2021"""
4
5  # LIBRERIAS IMPORTADAS
6  import numpy as np
7  import matplotlib.pyplot as plt
8  import pandas as pd
9  import seaborn as sns
10 from sklearn.preprocessing import MinMaxScaler
11 from keras.models import Sequential
12 from keras.layers import Dense, LSTM, GRU
13 from sklearn.linear_model import LinearRegression
14 from sklearn.metrics import r2_score
15 from sklearn.metrics import mean_squared_error
16 import statsmodels.api as sm
17
18
19 # Funciones auxiliar para grafica de predicciones y datos reales
20
21 def graficar_todo(real, prediccion):
22     plt.plot(real[0:len(prediccion)],color='black', label='Valor real del PBI de Peru')
23     plt.plot(prediccion, color='red', label='Predicción del PBI de Peru')
24     plt.axvline(x=124, color="black", linestyle='--', ymin=0.1, ymax=0.9)
25     # plt.axvline(x=pd.to_datetime('2010-12-31'), color="black", linestyle='--', ymin=0.1, ymax=0.9)
26     plt.title('DATOS REALES Y ESTIMADOS')
27     plt.ylim(1.1 * np.min(real)/2, 1.1 * np.max(real))
28     plt.xlabel('Años')
29     plt.ylabel('Valor del PBI de Peru')
30     plt.legend()
31     plt.show()
32
33 def graficar_solo_comportamiento(real, prediccion):
34     plt.plot(real[:124], color='black', label='Valor real del PBI de Peru')
35     plt.plot(prediccion[:124], color='red', label='Predicción del PBI de Peru')
36     plt.title('DATOS REALES Y ESTIMADOS')
37     plt.ylim(1.1 * np.min(real)/2, 1.1 * np.max(real))
38     plt.xlabel('Años')
39     plt.ylabel('Valor del PBI de Peru')
40     plt.legend()
41     plt.show()

```

```

42
43 def graficar_solo_prediccion(real, prediccion):
44     plt.plot(real[124:len(prediccion)], color='black', label='Valor real del PBI de Perú')
45     plt.plot(prediccion[124:], color='red', label='Predicción del PBI de Perú')
46     plt.title('DATOS REALES Y PREDECIDOS')
47     plt.ylim(1.1 * np.min(real)/2, 1.1* np.max(real))
48     plt.xlabel('Años')
49     plt.ylabel('Valor del PBI de Perú')
50     plt.legend()
51     plt.show()
52
53 def graficar_dispersion(real, prediccion):
54     real = real[0:len(prediccion)]
55     plt.scatter(real, prediccion, color= 'blue', marker='.')
56     plt.title('Dispersion de los valores reales y valores estimados (COMPORTAMIENTO Y PREDICCIÓN)')
57     plt.xlabel('valor real del PBI de Perú')
58     plt.ylabel('Valor predecido del PBI de Perú')
59
60     #LINEA DE TENDENCIA
61     modelo = LinearRegression()
62     modelo.fit(real,prediccion)
63     y = modelo.predict(real)
64
65     # Calcular la media de los valores reales
66     mean_y = np.mean(real)
67
68     # Calcular Suma de cuadrados totales - SST
69     sst = np.sum((real - mean_y)**2)
70
71     # Calcular Regresión de la suma de cuadrados - SSR
72     ssr = np.sum((y - mean_y)**2)
73
74     # Calcular Error de suma de cuadrados - SSE residuales
75     sse_residuales = np.sum((real - y)**2)
76
77     plt.plot(real, y, color= 'red', linestyle='-', label='LINEA DE TENDENCIA')
78
79     # Calcular el R2 del modelo en general del modelo de RN
80     r2 = r2_score(real, prediccion)
81     print(f"R2 en general del modelo de RN: {r2}")
82
83     # Imprimir coeficientes
84     print('Coeficiente (pendiente):', modelo.coef_[0])
85     print('Intersección:', modelo.intercept_)

```

```

86
87 #R CUADRADO TODO_LOS DATOS
88 print("Suma de Cuadrados Total (SST):", sst)
89 print("Suma de Cuadrados de Regresión (SCR):", ssr)
90 print("Suma de Cuadrados Residuales (SSE):", sse_residuales)
91 print("Coeficiente de determinación R^2 (COMPORTAMIENTO Y PREDICCIÓN):", modelo.score(real, prediccion))
92 plt.show()
93
94 def graficar_dispersión_comportamiento(real, prediccion):
95     real = real[:124]
96     prediccion = prediccion[:124]
97     plt.scatter(real, prediccion, color= 'blue', marker='.')
98     plt.title('Dispersión de los valores reales y valores estimados (COMPORTAMIENTO)' )
99     plt.xlabel('valor real del PBI de Perú')
100    plt.ylabel('Valor predicho del PBI de Perú')
101
102    #LINEA DE TENDENCIA
103    modelo = LinearRegression()
104    modelo.fit(real,prediccion)
105    y = modelo.predict(real)
106
107    # Calcular la media de los valores reales
108    mean_y = np.mean(real)
109
110    # Calcular Suma de cuadrados totales - SST
111    sst = np.sum((real - mean_y)**2)
112
113    # Calcular Regresión de la suma de cuadrados - SSR
114    ssr = np.sum((y - mean_y)**2)
115
116    # Calcular Error de suma de cuadrados - SSE residuales
117    sse_residuales = np.sum((real - y)**2)
118
119    plt.plot(real, y, color= 'red', linestyle='-', label='LINEA DE TENDENCIA')
120
121    # Calcular el R^2 del modelo en general del modelo de RN
122    r2 = r2_score(real, prediccion)
123    print(f"R^2 en general del modelo de RN: {r2}")
124
125    # Imprimir coeficientes
126    print('Coeficiente (pendiente):', modelo.coef_[0])
127    print('Intersección:', modelo.intercept )

```

```

128
129 #R CUADRADO TODO_LOS DATOS
130 print("Suma de Cuadrados Total (SST):", sst)
131 print("Suma de Cuadrados de Regresión (SCR):", ssr)
132 print("Suma de Cuadrados Residuales (SSE):", sse_residuales)
133 print("Coeficiente de determinación R^2 (COMPORTAMIENTO Y PREDICCIÓN):", modelo.score(real, prediccion))
134 plt.show()
135
136 def graficar_dispesion_prediccion(real, prediccion):
137     real = real[124:len(prediccion)]
138     prediccion = prediccion[124:]
139     plt.scatter(real, prediccion, color= 'blue', marker='.')
140     plt.title('Dispersion de los valores reales y valores predecidos (SOLO PREDICION)')
141     plt.xlabel('valor real del PBI de Perú')
142     plt.ylabel('Valor predecido del PBI de Perú')
143
144     #LINEA DE TENDENCIA
145     modelo = LinearRegression()
146     modelo.fit(real,prediccion)
147     y = modelo.predict(real)
148
149     # Calcular la media de los valores reales
150     mean_y = np.mean(real)
151
152     # Calcular Suma de cuadrados totales - SST
153     sst = np.sum((real - mean_y)**2)
154
155     # Calcular Regresión de la suma de cuadrados - SSR
156     ssr = np.sum((y - mean_y)**2)
157
158     # Calcular Error de suma de cuadrados - SSE residuales
159     sse_residuales = np.sum((real - y)**2)
160
161     plt.plot(real, y, color= 'red', linestyle='-', label='LINEA DE TENDENCIA')
162
163     # Calcular el R^2 del modelo en general del modelo de RN
164     r2 = r2_score(real, prediccion)
165     print(f"R^2 en general del modelo de RN: {r2}")
166
167     # Imprimir coeficientes
168     print('Coeficiente (pendiente):', modelo.coef_[0])
169     print('Intersección:', modelo.intercept_)
170

```

```

171 #R CUADRADO TODO_LOS DATOS
172 print("Suma de Cuadrados Total (SST):", sst)
173 print("Suma de Cuadrados de Regresión (SCR):", sss)
174 print("Suma de Cuadrados Residuales (SSE):", sse_residuales)
175 print("Coeficiente de determinación R^2 (COMPORTAMIENTO Y PREDICIÓN):", modelo.score(real, prediccion))
176 plt.show()
177
178 # Lectura de los datos (Base de datos)
179 # Se lee el archivo de Excel que contiene los datos y se almacenan en el dataframe 'dataset'
180 # El archivo se encuentra en la ruta 'D:/Carpeta Escritorio/tesis rna/datos/Base de datos.xlsx'
181 # La columna 'Date' se utiliza como índice y se interpreta como fechas
182 dataset = pd.read_excel('D:/base de datos/Base de datos.xlsx', index_col='Date', parse_dates=['Date'])
183 dataset.head()
184
185
186 # Análisis descriptivo de los datos
187 # Imprimir las estadísticas descriptivas del dataset
188 print("Estadísticas descriptivas del dataset:")
189 print(dataset.describe())
190
191 # Histograma del PBI de Perú
192 plt.figure(figsize=(10, 6))
193 sns.histplot(dataset['PBI PEN'], bins=20, kde=True)
194 plt.title('Histograma del PBI de Perú')
195 plt.xlabel('PBI PEN')
196 plt.ylabel('Frecuencia')
197 plt.show()
198
199 """"DATOS OBSERVADOS Y DATOS DE ENTRENAMIENTO (Separación de datos)""""
200 """"TOTAL DE DATOS = 168""""
201 # La RNA se entrenará con datos desde el primer trimestre de 1980 hasta el cuarto trimestre de 2010.
202 # Se selecciona una porción del conjunto de datos original, limitando las fechas hasta el año 2010 (inclusive)
203 # Solo se considera la segunda columna de datos para el entrenamiento
204 datos_entrenamiento= dataset['2010'].iloc[:,1:2]
205
206 # Los datos desde el primer trimestre del 2011 hasta el cuarto trimestre del 2021 son datos que el modelo desconoce.
207 # Se selecciona otra porción del conjunto de datos original, comenzando desde el año 1980 hasta el final
208 # También se considera solo la segunda columna de datos para la observación
209 datos_observados = dataset['1980:'].iloc[:,1:2]
210
211
212 datos_prediccion = dataset['2011':'2021'].iloc[:,1:2]
213

```

Haga clic para agregar un punto de interrupción

```

215 datos_observados['PBI PEN'].plot(legend=True)
216
217 # Gráfico de los datos de entrenamiento
218 # Se utiliza una línea punteada de color negro para distinguirlos de los datos observados
219 datos_entrenamiento['PBI PEN'].plot(linestyle='--', color='black', legend=True)
220
221 # Configuración del título y las leyendas del gráfico
222 plt.title('TOTAL DE DATOS')
223 plt.legend(['Datos Observados (1980-2020)', 'Datos de Entrenamiento (1980-2010)'])
224
225 # Mostrar el gráfico
226 plt.show()
227
228 print("estadísticas descriptivas para datos que el modelo conoce (comportamiento)")
229 print(datos_entrenamiento.describe())
230
231 print("estadísticas descriptivas para datos que el modelo no conoce (predicción)")
232 print(datos_prediccion.describe())
233
234 # Normalización de los datos de entrenamiento
235 # Se utiliza el escalador MinMaxScaler para transformar los datos en una escala de 0 a 1
236 sc = MinMaxScaler(feature_range=(0, 1))
237 datos_entrenamiento_escalado = sc.fit_transform(datos_entrenamiento)
238
239 # Gráfico de los datos normalizados
240 # Se traza la secuencia de valores normalizados en función del índice de muestra
241 plt.plot(datos_entrenamiento_escalado)
242 plt.xlabel('Índice de muestra')
243 plt.ylabel('Valor normalizado')
244 plt.title('Datos de entrenamiento normalizados')
245 plt.show()
246
247 # La RNA tendrá como entrada "dato_entrada" datos consecutivos, y como salida 1 dato (la predicción a partir de esos "dato_entrada" datos).
248 # Se conformará de esta forma el set de entrenamiento
249 dato_entrada = 2
250
251 # Listas para almacenar los datos de entrenamiento
252 X_train = []
253 Y_train = []
254

```

```

255 # Obtener la longitud total de los datos de entrenamiento normalizados
256 m = len(datos_entrenamiento_escalado)
257
258 # Generar los datos de entrenamiento y salida correspondientes
259 for i in range(dato_entrada, m):
260     # X: bloques de "dato_entrada" datos consecutivos
261     bloque_entrenamiento = datos_entrenamiento_escalado[i - dato_entrada : i, 0]
262     X_train.append(bloque_entrenamiento)
263
264     # Y: el siguiente dato después del bloque de "dato_entrada"
265     siguiente_dato = datos_entrenamiento_escalado[i, 0]
266     Y_train.append(siguiente_dato)
267
268 # Convertir las listas en matrices numpy
269 X_train = np.array(X_train)
270 Y_train = np.array(Y_train)
271
272 # Ajustar la forma de X_train para que se ajuste al modelo en Keras
273 # La nueva forma será (número de muestras, número de pasos de tiempo, número de características)
274 X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1))
275
276 # Definición de la estructura de la RNA LSTM
277
278 # Dimensiones de entrada para la RNA LSTM
279 dim_entrada = (X_train.shape[1], 1)
280
281 # Creación del modelo secuencial
282 modelo = Sequential()
283
284 # Capa LSTM con 20 unidades y función de activación tangente hiperbólica
285 modelo.add(LSTM(units=20, input_shape=dim_entrada, activation='tanh'))
286
287 # Capa densa de salida con 1 unidad
288 modelo.add(Dense(units=1))
289
290 # Compilación del modelo con optimizador RMSprop y función de pérdida MSE
291 modelo.compile(optimizer='RMSprop', loss='mse')
292
293 # Impresión de mensaje de inicio del entrenamiento
294 print("Comenzando entrenamiento del modelo...")
295
296 # Entrenamiento del modelo con los datos de entrada X_train y las salidas Y_train
297 historia = modelo.fit(X_train, Y_train, epochs=40, batch_size=10, validation_split=0.2, verbose=True)
298

```

```

299 # Impresión de mensaje de fin del entrenamiento
300 print("Entrenamiento del modelo terminado")
301
302 # Curva de aprendizaje de la RNA
303
304 # Obtención de las curvas de pérdida durante el entrenamiento
305 loss = historia.history['loss']
306 val_loss = historia.history['val_loss']
307
308 # Gráfico de las curvas de pérdida
309 plt.plot(loss, label='Entrenamiento')
310 plt.plot(val_loss, label='Validación')
311 plt.xlabel('# épocas')
312 plt.ylabel('Pérdida')
313 plt.legend()
314 plt.title('Curva de aprendizaje del modelo')
315 plt.show()
316
317 # Gráfico de la magnitud de pérdida a lo largo de las épocas
318 plt.plot(historia.history["loss"])
319 plt.xlabel("# época")
320 plt.ylabel("Magnitud de pérdida")
321 plt.title('Curva de aprendizaje del modelo')
322 plt.show()
323
324 # Preparación de los datos de prueba
325 x_test = datos_observados.values
326 x_test = sc.transform(x_test)
327
328 X_test = []
329
330 # Generación de los datos de prueba en bloques de tamaño "dato_entrada"
331 for i in range(dato_entrada, len(x_test)):
332     X_test.append(x_test[i-dato_entrada:i, 0])
333
334 X_test = np.array(X_test)
335 X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
336
337 """Realización de predicciones después del entrenamiento"""
338
339 # Se utiliza el modelo entrenado para realizar predicciones sobre los datos de prueba
340 prediccion = modelo.predict(X_test)
341 prediccion = sc.inverse transform(prediccion)

```

```

342
343 df_predicciones = pd.DataFrame(prediccion, columns=["Prediccion"])
344 df_predicciones.to_excel("D:/base de datos/predicciones.xlsx", index=False)
345
346 # Las predicciones resultantes se almacenan en la variable 'prediccion'
347 # Estas representan los valores estimados por la RNA para los datos de prueba
348 # El modelo utiliza los datos de entrada 'X_test' y genera las predicciones correspondientes
349
350 # Variables internas del modelo
351
352
353
354 print("Variables internas del modelo:")
355 for capa in modelo.layers:
356     # Obtener la configuración de la capa y los pesos asociados
357     config_capa = capa.get_config()
358     pesos_capa = capa.get_weights()
359     print("Configuración de la capa:")
360     print(repr(config_capa)) # Usar repr() en lugar de str()
361     print("Pesos de la capa:")
362     for peso in pesos_capa:
363         print(repr(peso)) # Usar repr() en lugar de str()
364     print("-" * 80)
365
366
367 # Graficar todos los resultados: datos observados y predicciones
368 graficar_todo(datos_observados.valores, prediccion)
369
370 # Graficar solo el comportamiento: datos observados y predicciones en el mismo gráfico
371 graficar_solo_comportamiento(datos_observados.valores, prediccion)
372
373 # Graficar solo las predicciones
374 graficar_solo_prediccion(datos_observados.valores, prediccion)
375
376 # Graficar la dispersión entre los datos reales y los datos predichos
377 graficar_dispesion(datos_observados.valores, prediccion)
378
379 # Graficar solo la dispersión del comportamiento: datos observados y predicciones en el mismo gráfico
380 graficar_dispesion_comportamiento(datos_observados.valores, prediccion)
381
382 # Graficar solo la dispersión de las predicciones
383 graficar_dispesion_prediccion(datos_observados.valores, prediccion)

```

VARIABLES INTERNAS DEL MODELO, CONFIGURACIÓN DE CAPAS Y PARETOS

Dimensiones de las matrices

Parámetros de la capa LSTM:	
Matriz de pesos	(1, 80)
Matriz de pesos recurrentes	(80, 80)
Vector de sesgos	(80,)

Parámetros de la capa Dense:	
Matriz de pesos	(80, 1)
Vector de sesgos	(1,)

Pesos de la capa:

```
array([[ 0.01797132,  0.02550432, -0.1690984 ,  0.00333203,  0.18490516,
        -0.13022994,  0.17364815,  0.10592438,  0.07728877, -0.17446984,
         0.06895617,  0.27364573,  0.3401892 ,  0.19824375, -0.1812691 ,
         0.12766108,  0.1908839 ,  0.12794483,  0.05826832,  0.00319556,
        -0.04118088,  0.12033528,  0.03916354, -0.12565294,  0.15882386,
         0.06073168,  0.01262727,  0.12253177,  0.13924845,  0.10836019,
        -0.04824166,  0.21145387,  0.0057232 ,  0.12172246, -0.06391422,
         0.03546595, -0.12699898, -0.21173687, -0.14943828, -0.13024579,
        -0.16817664,  0.18411055,  0.055231 ,  0.240165 , -0.4494782 ,
        -0.1942912 ,  0.268432 , -0.3050886 , -0.32191348,  0.14900978,
        -0.08397591, -0.25368086, -0.4021553 ,  0.02722336, -0.14003386,
        -0.29209447, -0.04620984, -0.0733372 , -0.15569024, -0.41623044,
         0.06432161,  0.00589145,  0.00325891,  0.26737562, -0.03312282,
         0.1996117 ,  0.11136564,  0.11000896,  0.22052415,  0.2075746 ,
```

```

-0.05966739, 0.02852747, 0.34176213, 0.02227781, -0.05472926,
0.09616967, 0.14519097, 0.1691769 , 0.25822693, 0.1740477 ]],
dtype=float32)
array([[ -0.04528209, 0.25188005, 0.01508833, ..., -0.01139856,
0.10585112, -0.00413214],
[ 0.03782297, 0.03218716, 0.05529861, ..., -0.09295513,
-0.00831951, 0.13252445],
[ 0.05168854, 0.16110346, -0.05515703, ..., -0.07174338,
0.10997652, 0.03325989],
...,
[ -0.04914493, 0.00971177, 0.04544995, ..., -0.07931228,
-0.18006505, -0.04833663],
[ -0.17685245, -0.15647893, -0.03662494, ..., 0.11077309,
-0.09029283, 0.28051394],
[ 0.15001327, -0.02789249, -0.06669839, ..., 0.00783255,
0.04419318, -0.22873507]], dtype=float32)
array([ 5.54588027e-02, 7.41161555e-02, -2.11315453e-02, 1.20617501e-01,
1.50847390e-01, 5.03015965e-02, 5.51689155e-02, 1.13626353e-01,
5.03909290e-02, 4.33505513e-02, -1.05662858e-02, 8.76656175e-02,
1.54372871e-01, -5.03601804e-02, 8.04327521e-03, 8.80843028e-02,
-3.22959386e-02, -7.15019833e-03, 3.36266384e-02, 1.15318820e-01,
1.01344752e+00, 1.01543701e+00, 9.90968406e-01, 1.03701782e+00,
1.05948663e+00, 1.01216078e+00, 1.01006365e+00, 1.02959096e+00,
1.01054084e+00, 1.00706911e+00, 9.99125242e-01, 1.02036047e+00,

```

```

1.07595909e+00, 9.79393303e-01, 1.00349939e+00, 1.01799750e+00,
9.92201686e-01, 9.96541739e-01, 1.00621486e+00, 1.03663075e+00,
9.19800252e-04, -1.86054921e-03, -6.09365106e-03, 1.73676154e-03,
3.83839011e-03, -2.03833310e-03, 4.66640387e-03, -3.63964378e-03,
-4.91558248e-03, -2.12323363e-03, -7.62075069e-04, -5.87351574e-03,
-8.75558797e-03, -6.74520200e-03, 1.02193048e-02, -2.62143626e-03,
-7.73634342e-03, -6.38362858e-03, -1.55634212e-03, 1.49100309e-03,
5.48781753e-02, 7.54630268e-02, -2.14357451e-02, 1.16180673e-01,
1.54095113e-01, 4.63159904e-02, 5.57875074e-02, 1.13592006e-01,
4.93491217e-02, 3.88105400e-02, -1.04268137e-02, 9.19800848e-02,
1.54539034e-01, -5.03147803e-02, 7.49964919e-03, 8.91602412e-02,
-3.23102400e-02, -7.23362481e-03, 3.15753147e-02, 1.13272920e-01],
dtype=float32)

```

Configuración de la capa:

```

{'name': 'dense', 'trainable': True, 'dtype': 'float32', 'units': 1, 'activation': 'linear',
'use_bias': True, 'kernel_initializer': {'module': 'keras.initializers', 'class_name':
'GlorotUniform', 'config': {'seed': None}, 'registered_name': None}, 'bias_initializer':
{'module': 'keras.initializers', 'class_name': 'Zeros', 'config': {}, 'registered_name':
None}, 'kernel_regularizer': None, 'bias_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None}

```

Pesos de la capa:

```

array([[ -0.6114045 ],
       [ 0.5813207 ],
       [ 0.30795693 ],
       [ 0.68764544 ],

```

```
[-0.51775295],  
[-0.396221 ],  
[ 0.21945585],  
[-0.4190342 ],  
[-0.20322765],  
[ 0.5852362 ],  
[-0.10877055],  
[-0.3963989 ],  
[-0.6832968 ],  
[-0.2386706 ],  
[-0.32614765],  
[-0.3024837 ],  
[-0.2134666 ],  
[-0.20094305],  
[-0.34237474],  
[-0.35538906]], dtype=float32)  
array([-0.00141279], dtype=float32)
```

ANEXO 05**NOTA BIOGRÁFICA****ALVAREZ FLORES JHON HARRINSON**

Nació el 09 de julio de 2001 en la provincia de Ambo, departamento de Huánuco. Cursó sus estudios secundarios en la I.E. Julio Benavides Sanguinetti, completándolos en 2017. En 2018, inició su formación universitaria en la Facultad de Economía de la Universidad Nacional Hermilio Valdizan, donde obtuvo el grado de bachiller en Economía en el año 2023. En su carrera profesional, se ha desempeñado en el sector público y privado, empleando los aprendizajes adquiridos durante sus estudios universitarios.

ENRIQUEZ MONTES CRHISTIAN JHON

Nació el 17 de septiembre de 1999 en el distrito de Huánuco, en el departamento de Huánuco. Cursó sus estudios secundarios en el Colegio de la I.E. Gran Unidad Leoncio Prado. En 2018, inició su formación universitaria en la Facultad de Economía de la Universidad Nacional Hermilio Valdizan, donde obtuvo el grado de bachiller en Economía el año 2023. En su carrera profesional, ha aplicado sus conocimientos en el Área Administrativa del Programa de Desarrollo Productivo Agrario Rural, empleando los aprendizajes adquiridos durante sus estudios universitarios.

TINEO CRUZ RAFAELA CAROLINA

Nació el 19 de septiembre de 2001 en el distrito de Carmen de la Legua, provincia constitucional del Callao y departamento de Lima. Cursó sus estudios secundarios en el Colegio Nacional de Aplicación UNHEVAL, completándolos en 2017. En 2018, inició su formación universitaria en la Facultad de Economía de la Universidad Nacional Hermilio Valdizan, donde obtuvo el grado de bachiller en Economía en el año 2023. En su carrera profesional, ha aplicado sus conocimientos en la Oficina General de Planeamiento y Presupuesto de la Municipalidad Distrital de Santa María del Valle, empleando los aprendizajes adquiridos durante sus estudios universitarios.

ANEXO 06

ACTA DE SUSTENTACIÓN



UNHEVAL
UNIVERSIDAD NACIONAL HERIBERTO VALCADA

RECTORADO

FACULTAD
DE ECONOMÍA

"Decenio de la Igualdad de Oportunidades para Mujeres y Hombres"

"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

ACTA DE SUSTENTACIÓN DE TESIS PARA OPTAR EL TÍTULO PROFESIONAL

En la ciudad universitaria de Cayhuayna, siendo las 11:00 a.m. horas del día **jueves 1 de agosto del 2024**, nos reunimos en el auditorio de la Facultad de ECONOMÍA de la UNHEVAL, los miembros integrantes del Jurado Evaluador:

Dr. Lizardo CAICEDO DAVILA PRESIDENTE
Mg. Emigdio RAMOS CORNELIO SECRETARIO
Dr. Christian Paolo MARTEL CARRANZA VOCAL

Acreditados mediante Resolución N° 368-2023-UNHEVAL-FE-D, de fecha 26.SET.2023, de la tesis titulada "NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980-2021", presentado por los titulandos **Jhon Harrinson ALVAREZ FLORES, Christian Jhon ENRIQUEZ MONTES y Rafaela Carolina TINEO CRUZ**, con el asesoramiento del docente **Dr. Clayton ALVARADO CHAVEZ**, se procedió a dar inicio el acto de sustentación para optar el Título Profesional de ECONOMISTA.

Concluido el acto de sustentación, cada miembro del Jurado Evaluador procedió a la evaluación de los titulandos **Jhon Harrinson ALVAREZ FLORES, Christian Jhon ENRIQUEZ MONTES y Rafaela Carolina TINEO CRUZ**, teniendo presente los siguientes criterios:

1. Presentación personal.
2. Exposición: el problema a resolver, hipótesis, objetivos, resultados, conclusiones, los aportes, contribución a la ciencia y/o solución a un problema social y recomendaciones.
3. Grado de convicción y sustento bibliográfico utilizados para las respuestas a las interrogantes del Jurado.
4. Dicción y dominio de escenario.

Nombres y Apellidos del Titulando	Jurado Evaluador			Promedio Final
	Presidente	Secretario	Vocal	
Jhon Harrinson ALVAREZ FLORES	16	16	16	16
Christian Jhon ENRIQUEZ MONTES	16	16	16	16
Rafaela Carolina TINEO CRUZ	16	16	16	16

Obteniendo en consecuencia:

El titulando **Jhon Harrinson ALVAREZ FLORES** la nota de Dieciséis (16), equivalente a Buena, por lo que se declara Aprabado.

El titulando **Christian Jhon ENRIQUEZ MONTES** la nota de Dieciséis (16), equivalente a Buena, por lo que se declara Aprabado.

La titulando **Rafaela Carolina TINEO CRUZ** la nota de Dieciséis (16), equivalente a Buena, por lo que se declara Aprabado.

Calificación que se realiza de acuerdo con el Art. 46° del Reglamento de Grados y Títulos 2024 de la UNHEVAL.

Se da por finalizado el presente acto, siendo las 12:34 p.m. horas, del día **jueves 1 de agosto del 2024**, firmando en señal de conformidad.


PRESIDENTE
DNI N° 22405065


SECRETARIO
DNI N° 22435369


VOCAL
DNI N° 41608365

Leyenda:
19 a 20: Excelente
17 a 18: Muy Bueno
14 a 16: Bueno
0 a 13: Desaprobado

Av. Universitaria 601-607- Ciudad Universitaria - Cayhuayna - Pillco Marca - Pabellón 9 - Primer Piso
Facultad de Economía

EMPRESA
SOCIEDAD
UNIVERSIDAD

ANEXO 07

CONSTANCIA DE SIMILITUD Y REPORTE

**UNIVERSIDAD NACIONAL "HERMILIO VALDIZÁN"***Licenciada con Resolución del Consejo Directivo N° 099-2019-S/UNEDU/CD***FACULTAD DE ECONOMÍA
ESCUELA PROFESIONAL DE ECONOMÍA
CARRERA PROFESIONAL DE ECONOMÍA****CONSTANCIA DE SIMILITUD N° 012-2024-SOFTWARE ANTIPLAGIO
TURNITIN-EP/FE-UNHEVAL.**

El Director de la Unidad de Investigación de la Facultad de Economía, emite la presente CONSTANCIA DE SIMILITUD, aplicando el Software TURNITIN, la cual reporta un 30 % de similitud, correspondiente a los interesados **Jhon Harrinson ALVAREZ FLORES, Crhistian Jhon ENRIQUEZ MONTES, Rafaela Carolina TINEO CRUZ**, de la tesis **"NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980-2021"**, cuyo asesor es el Dr. Clayton ALVARADO CHAVEZ; por consiguiente

SE DECLARA APTO

Se expide la presente, para los trámites pertinentes.

Cayhuayna, 25 de junio de 2024


Dr. **Christian Paolo MARTEL CARRANZA**
Director de la Unidad de Investigación
de la Facultad de Economía
UNHEVAL

Reporte de similitud

<p>NOMBRE DEL TRABAJO</p> <p>NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980-2021</p>	<p>AUTORES</p> <p>JHON HARRINSON ALVAREZ FLORES CRHISTIAN JHON ENRIQUEZ MONTES RAFAELA CAROLINA TINEO CRUZ</p>
<p>RECUENTO DE PALABRAS</p> <p>20260 Words</p>	<p>RECUENTO DE CARACTERES</p> <p>118803 Characters</p>
<p>RECUENTO DE PÁGINAS</p> <p>99 Pages</p>	<p>TAMAÑO DEL ARCHIVO</p> <p>2.8MB</p>
<p>FECHA DE ENTREGA</p> <p>Jun 24, 2024 5:19 PM GMT-5</p>	<p>FECHA DEL INFORME</p> <p>Jun 24, 2024 5:21 PM GMT-5</p>

● 30% de similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 20% Base de datos de Internet
- Base de datos de Crossref
- 25% Base de datos de trabajos entregados
- 5% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

Resumen

Reporte de similitud
Reporte de similitud

● 30% de similitud general

Principales fuentes encontradas en las siguientes bases de datos:

- 20% Base de datos de Internet
- Base de datos de Crossref
- 25% Base de datos de trabajos entregados
- 5% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

FUENTES PRINCIPALES

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	repositorio.unheval.edu.pe Internet	3%
2	github.com Internet	2%
3	Universidad Francisco de Vitoria on 2023-04-30 Submitted works	<1%
4	hdl.handle.net Internet	<1%
5	coursehero.com Internet	<1%
6	Universidad Politécnica de Madrid on 2024-06-10 Submitted works	<1%
7	livrosdeamor.com.br Internet	<1%
8	Universidad Internacional de la Rioja on 2023-05-10 Submitted works	<1%

Descripción general de fuentes

		Reporte de similitud
9	inteligenciartificialmca.wordpress.com Internet	<1%
10	ichi.pro Internet	<1%
11	repositorio.ug.edu.ec Internet	<1%
12	Universidad Internacional Isabel I de Castilla on 2023-11-02 Submitted works	<1%
13	Universidad Internacional de la Rioja on 2024-06-09 Submitted works	<1%
14	repositorio.upagu.edu.pe Internet	<1%
15	fce.unal.edu.co Internet	<1%
16	repositorio.unprg.edu.pe Internet	<1%
17	Universidad Politecnica Salesiana del Ecuador on 2024-01-17 Submitted works	<1%
18	Institución Universitaria Digital de Antioquia on 2023-10-01 Submitted works	<1%
19	fieecs.uni.edu.pe Internet	<1%
20	ITESM: Instituto Tecnológico y de Estudios Superiores de Monterrey o... Submitted works	<1%

Descripción general de fuentes

Subir el archivo		Reporte de similitud
21	Universidad Carlos III de Madrid - EUR on 2024-06-12 Submitted works	<1%
22	Universidad Carlos III de Madrid - EUR on 2024-06-12 Submitted works	<1%
23	repositorio.unac.edu.pe Internet	<1%
24	researchgate.net Internet	<1%
25	Universidad Internacional de la Rioja on 2024-04-01 Submitted works	<1%
26	scribd.com Internet	<1%
27	slideshare.net Internet	<1%
28	qdoc.tips Internet	<1%
29	repositorio.ucv.edu.pe Internet	<1%
30	Birkbeck College on 2021-01-14 Submitted works	<1%
31	Universidad de Málaga - Tii on 2023-09-10 Submitted works	<1%
32	Universidad Internacional de la Rioja on 2023-11-16 Submitted works	<1%

Descripción general de fuentes

33	ITESM: Instituto Tecnológico y de Estudios Superiores de Monterrey o...	Submitted works	<1%
34	Universidad Internacional de la Rioja on 2024-05-13	Submitted works	<1%
35	Universidad Loyola Andalucía on 2024-06-24	Submitted works	<1%
36	Universidad Internacional de la Rioja on 2024-01-18	Submitted works	<1%
37	Universidad de Alcalá on 2023-06-29	Submitted works	<1%
38	Universitat Politècnica de València on 2015-01-19	Submitted works	<1%
39	pdfcoffee.com	Internet	<1%
40	Universidad de Guayaquil on 2024-01-30	Submitted works	<1%
41	Universidad Internacional de la Rioja on 2023-06-02	Submitted works	<1%
42	Universidad Internacional de la Rioja on 2023-07-20	Submitted works	<1%
43	Universidad TecMilenio on 2024-02-09	Submitted works	<1%
44	los150anosdelcsg.blogspot.com	Internet	<1%

Descripción general de fuentes

Repositorio de similitud	
45	repositorio.usmp.edu.pe Internet <1%
46	repositorio.utc.edu.ec Internet <1%
47	ri.uaemex.mx Internet <1%
48	Universidad Anahuac México Sur on 2024-05-05 Submitted works <1%
49	Universidad Científica del Sur on 2022-01-18 Submitted works <1%
50	Universidad Internacional de la Rioja on 2024-06-09 Submitted works <1%
51	Infile on 2020-08-28 Submitted works <1%
52	juandomingofarnos.wordpress.com Internet <1%
53	repositorio.udh.edu.pe Internet <1%
54	Infile on 2023-12-18 Submitted works <1%
55	Infile on 2024-02-25 Submitted works <1%
56	Universidad Internacional de la Rioja on 2024-06-12 Submitted works <1%

Descripción general de fuentes

Reporte de similitud		
57	cespe.espe.edu.ec Internet	<1%
58	repository.unimilitar.edu.co Internet	<1%
59	Universidad TecMilenio on 2024-01-24 Submitted works	<1%
60	docplayer.es Internet	<1%
61	Universidad Anahuac México Sur on 2023-10-30 Submitted works	<1%
62	Universidad EAN on 2024-05-01 Submitted works	<1%
63	Universidad Nacional Abierta y a Distancia, UNAD,UNAD on 2024-06-08 Submitted works	<1%
64	Universidad TecMilenio on 2024-05-12 Submitted works	<1%
65	Universidad TecMilenio on 2024-06-10 Submitted works	<1%
66	Universidad Tecnica De Ambato- Direccion de Investigacion y Desarrol... Submitted works	<1%
67	Universidad San Francisco de Quito on 2023-05-02 Submitted works	<1%
68	repositorio.ujcm.edu.pe Internet	<1%

Descripción general de fuentes

		Reporte de similitud
69	repositorio.uni.edu.pe Internet	<1%
70	redalyc.org Internet	<1%
71	Corporación Universitaria Minuto de Dios, UNIMINUTO on 2023-08-21 Submitted works	<1%
72	Infile on 2023-05-23 Submitted works	<1%
73	Infile on 2023-12-18 Submitted works	<1%
74	Pontificia Universidad Catolica del Peru on 2024-06-13 Submitted works	<1%
75	Universidad Anahuac México Sur on 2023-12-04 Submitted works	<1%
76	Universidad Internacional de la Rioja on 2023-09-19 Submitted works	<1%
77	Universidad Politécnica de Madrid on 2020-05-18 Submitted works	<1%
78	Universidad de Valladolid on 2024-05-29 Submitted works	<1%
79	dspace.unitru.edu.pe Internet	<1%
80	codificandobits.com Internet	<1%

Descripción general de fuentes

Reporte de similitud	
81	<p>Universidad TecMilenio on 2024-01-19 Submitted works</p> <p><1%</p>
82	<p>Universidad Carlos III de Madrid on 2019-09-10 Submitted works</p> <p><1%</p>
83	<p>Universidad Internacional de la Rioja on 2023-11-28 Submitted works</p> <p><1%</p>
84	<p>Universidad Internacional de la Rioja on 2024-05-12 Submitted works</p> <p><1%</p>
85	<p>Universidad de Málaga - Tii on 2021-09-25 Submitted works</p> <p><1%</p>
86	<p>issuu.com Internet</p> <p><1%</p>
87	<p>repositorio.pascualbravo.edu.co Internet</p> <p><1%</p>
88	<p>repositorio.uap.edu.pe Internet</p> <p><1%</p>
89	<p>Universidad Internacional de la Rioja on 2022-03-02 Submitted works</p> <p><1%</p>
90	<p>Universidad Internacional de la Rioja on 2023-06-03 Submitted works</p> <p><1%</p>
91	<p>flacsoandes.edu.ec Internet</p> <p><1%</p>
92	<p>Infile on 2023-04-01 Submitted works</p> <p><1%</p>

Descripción general de fuentes

Reporte de similitud		Reporte de similitud
93	St. Peter's School on 2024-05-28 Submitted works	<1%
94	Universidad TecMilenio on 2024-01-20 Submitted works	<1%
95	Infile on 2023-05-23 Submitted works	<1%
96	Universidad Internacional de la Rioja on 2020-09-22 Submitted works	<1%
97	Universidad Internacional de la Rioja on 2023-06-03 Submitted works	<1%
98	Universidad Internacional de la Rioja on 2024-05-13 Submitted works	<1%
99	Universidad Internacional de la Rioja on 2024-05-13 Submitted works	<1%
100	idus.us.es Internet	<1%
101	Universidad Internacional de la Rioja on 2023-05-27 Submitted works	<1%
102	Universidad Ricardo Palma on 2020-06-19 Submitted works	<1%
103	Universitat Politècnica de València on 2020-09-02 Submitted works	<1%
104	pdfcookie.com Internet	<1%

Descripción general de fuentes

Fuente de similitud		Reporte de similitud
105	repositorio.cepal.org Internet	<1%
106	repositorio.comillas.edu Internet	<1%
107	upo.es Internet	<1%
108	Bachu Ganesh, S Sridevi. "Analysis of Hybrid Deep Learning Models for..." Crossref	<1%
109	Corporación Universitaria Iberoamericana on 2024-04-30 Submitted works	<1%
110	Corporación Universitaria Minuto de Dios, UNIMINUTO on 2023-10-17 Submitted works	<1%
111	Universidad Anahuac México Sur on 2024-05-20 Submitted works	<1%
112	Universidad Internacional de la Rioja on 2023-06-03 Submitted works	<1%
113	Yeny Rosas, Vanessa V. Valdés S. "Conocimientos, aptitudes y práctic..." Crossref	<1%
114	kipdf.com Internet	<1%
115	ITESM: Instituto Tecnológico y de Estudios Superiores de Monterrey o... Submitted works	<1%
116	Universidad Europea de Madrid on 2023-09-18 Submitted works	<1%

Descripción general de fuentes

Reporte de similitud	
117	<p>Universidad Internacional de la Rioja on 2023-09-20</p> <p>Submitted works</p> <p><1%</p>
118	<p>Universidad Politécnica de Madrid on 2023-07-02</p> <p>Submitted works</p> <p><1%</p>
119	<p>m.moam.info</p> <p>Internet</p> <p><1%</p>
120	<p>repositorio.ucm.edu.co</p> <p>Internet</p> <p><1%</p>
121	<p>repositorio.umch.edu.pe</p> <p>Internet</p> <p><1%</p>
122	<p>Caribbean University on 2023-08-03</p> <p>Submitted works</p> <p><1%</p>
123	<p>Corporación Universitaria Minuto de Dios, UNIMINUTO on 2023-07-03</p> <p>Submitted works</p> <p><1%</p>
124	<p>Institución Universitaria Digital de Antioquia on 2023-10-08</p> <p>Submitted works</p> <p><1%</p>
125	<p>Monforte Vargas, Carlos Sanchez Medina, Edinson Natividad Calder...</p> <p>Publication</p> <p><1%</p>
126	<p>Submitted on 1685622605550</p> <p>Submitted works</p> <p><1%</p>
127	<p>UNIV DE LAS AMERICAS on 2023-10-21</p> <p>Submitted works</p> <p><1%</p>
128	<p>Universidad Autónoma Metropolitana-Xochimilco on 2024-01-29</p> <p>Submitted works</p> <p><1%</p>

Descripción general de fuentes

Reporte de similitud	
129	<p>Universidad Internacional de la Rioja on 2023-06-02</p> <p>Submitted works</p> <p><1%</p>
130	<p>Universidad San Francisco de Quito on 2024-04-22</p> <p>Submitted works</p> <p><1%</p>
131	<p>Universidad TecMilenio on 2024-01-21</p> <p>Submitted works</p> <p><1%</p>
132	<p>Universidad TecMilenio on 2024-01-26</p> <p>Submitted works</p> <p><1%</p>
133	<p>biblioteca.uajms.edu.bo</p> <p>Internet</p> <p><1%</p>
134	<p>repositorio.unitec.edu</p> <p>Internet</p> <p><1%</p>
135	<p>economia.puc.cl</p> <p>Internet</p> <p><1%</p>
136	<p>"Applied Computer Sciences in Engineering", Springer Science and Bus...</p> <p>Crossref</p> <p><1%</p>
137	<p>Corporación Universitaria Minuto de Dios, UNIMINUTO on 2024-04-29</p> <p>Submitted works</p> <p><1%</p>
138	<p>Infile on 2023-12-18</p> <p>Submitted works</p> <p><1%</p>
139	<p>Infile on 2024-04-25</p> <p>Submitted works</p> <p><1%</p>
140	<p>Universidad Carlos III de Madrid - EUR on 2024-06-12</p> <p>Submitted works</p> <p><1%</p>

Descripción general de fuentes

Instituciones de origen		Reporte de similitud
141	Universidad Cesar Vallejo on 2023-08-07 Submitted works	<1%
142	Universidad Europea de Madrid on 2021-05-03 Submitted works	<1%
143	Universidad Europea de Madrid on 2022-07-08 Submitted works	<1%
144	Universidad Internacional de la Rioja on 2024-06-03 Submitted works	<1%
145	Universidad Militar Nueva Granada on 2023-11-14 Submitted works	<1%
146	Universidad Nacional Hermilio Valdizan on 2023-07-15 Submitted works	<1%
147	Universidad Privada del Norte on 2023-05-12 Submitted works	<1%
148	repositorio.unsch.edu.pe Internet	<1%
149	repositorio.utp.edu.pe Internet	<1%
150	Ana G. Méndez University on 2022-09-22 Submitted works	<1%
151	Corporación Universitaria Minuto de Dios, UNIMINUTO on 2023-10-12 Submitted works	<1%
152	Corporación Universitaria Minuto de Dios, UNIMINUTO on 2024-02-17 Submitted works	<1%

Descripción general de fuentes

Reporte de similitud

153	IPChile on 2023-09-12	Submitted works	<1%
154	Infile on 2021-04-09	Submitted works	<1%
155	Infile on 2023-04-01	Submitted works	<1%
156	Universidad Adolfo Ibáñez on 2023-06-06	Submitted works	<1%
157	Universidad Internacional de la Rioja on 2023-10-31	Submitted works	<1%
158	Universidad Internacional de la Rioja on 2024-02-02	Submitted works	<1%
159	Universidad Internacional de la Rioja on 2024-06-02	Submitted works	<1%
160	Universidad Internacional de la Rioja on 2024-06-09	Submitted works	<1%
161	cybertesis.unmsm.edu.pe	Internet	<1%
162	es.unionpedia.org	Internet	<1%
163	repositorio.unjfsc.edu.pe	Internet	<1%
164	repositorio.unsa.edu.pe	Internet	<1%

Descripción general de fuentes

similitud principal		Reporte de similitud
165	banrep.gov.co Internet	<1%
166	Aliaga Huidobro, Elizabeth. "Los determinantes del trabajo infantil rural..." Publication	<1%
167	Infile on 2022-12-31 Submitted works	<1%
168	National University College - Online on 2024-06-10 Submitted works	<1%
169	Universidad Europea de Madrid on 2023-10-16 Submitted works	<1%
170	Universidad Internacional de la Rioja on 2023-05-10 Submitted works	<1%
171	Universidad Internacional de la Rioja on 2024-05-12 Submitted works	<1%
172	Universidad Nacional Abierta y a Distancia, UNAD,UNAD on 2023-05-27 Submitted works	<1%
173	Universidad Nacional Abierta y a Distancia, UNAD,UNAD on 2024-06-09 Submitted works	<1%
174	Universidad de Salamanca on 2023-07-17 Submitted works	<1%
175	bibliotecavirtualoducal.uc.cl Internet	<1%
176	de.slideshare.net Internet	<1%

Descripción general de fuentes

		Reporte de similitud
177	e-catalog.nlb.by Internet	<1%
178	msal.gov.ar Internet	<1%
179	muchosensayos.com Internet	<1%
180	mymemory.translated.net Internet	<1%
181	quimbaya.banrep.gov.co Internet	<1%
182	repositorio.unab.edu.pe Internet	<1%
183	repositorio.uta.edu.ec Internet	<1%
184	statologos.jaol.net Internet	<1%
185	upb on 2024-05-16 Submitted works	<1%
186	exilia2.cl Internet	<1%
187	"Development of a simulation tool for the economic optimization of an ... Crossref posted content	<1%
188	Centro Europeo de Postgrado - CEUPE on 2024-05-09 Submitted works	<1%

Descripción general de fuentes

Instituto Tecnológico y de Estudios Superiores de Monterrey		Reporte de similitud
189	ITESM: Instituto Tecnológico y de Estudios Superiores de Monterrey o... Submitted works	<1%
190	ITESM: Instituto Tecnológico y de Estudios Superiores de Monterrey o... Submitted works	<1%
191	Mondragon Unibertsitatea on 2024-03-08 Submitted works	<1%
192	Sri Lanka Institute of Information Technology on 2022-11-20 Submitted works	<1%
193	Universidad Adolfo Ibáñez on 2023-06-06 Submitted works	<1%
194	Universidad Autónoma Latinoamericana on 2023-11-14 Submitted works	<1%
195	Universidad Internacional de la Rioja on 2020-07-22 Submitted works	<1%
196	Universidad Internacional de la Rioja on 2024-06-03 Submitted works	<1%
197	Universidad Internacional de la Rioja on 2024-06-03 Submitted works	<1%
198	Universidad Internacional de la Rioja on 2024-06-10 Submitted works	<1%
199	Universidad Nacional Abierta y a Distancia, UNAD,UNAD on 2024-05-15 Submitted works	<1%
200	Universidad Nacional Abierta y a Distancia, UNAD,UNAD on 2024-06-09 Submitted works	<1%

Descripción general de fuentes

Búsqueda de similitud		Reporte de similitud	
201	Universidad TecMilenio on 2024-05-11 Submitted works		<1%
202	abecedariochino.info Internet		<1%
203	americana.edu.co Internet		<1%
204	core.ac.uk Internet		<1%
205	documentop.com Internet		<1%
206	doku.pub Internet		<1%
207	dokumen.pub Internet		<1%
208	dspace.espol.edu.ec Internet		<1%
209	es.scribd.com Internet		<1%
210	openaccess.uoc.edu Internet		<1%
211	rstudio-pubs-static.s3.amazonaws.com Internet		<1%
212	worldwidescience.org Internet		<1%

Descripción general de fuentes

		Reporte de similitud
213	acader.unc.edu.ar Internet	<1%
214	bmv.com.mx Internet	<1%
215	esemanal.com.mx Internet	<1%
216	grafiat.com Internet	<1%
217	indec.mecon.gov.ar Internet	<1%
218	rioabierto.org Internet	<1%
219	tesisenred.net Internet	<1%
220	udp.cl Internet	<1%
221	Submitted works	<1%
222	Corporación Universitaria Minuto de Dios, UNIMINUTO on 2023-05-08 Submitted works	<1%
223	Corporación Universitaria Remington on 2024-04-08 Submitted works	<1%
224	Infile on 2023-04-01 Submitted works	<1%

Descripción general de fuentes

Reporte de similitud	
225	Infile on 2023-05-22 Submitted works <1%
226	Infile on 2024-04-17 Submitted works <1%
227	Infile on 2024-05-16 Submitted works <1%
228	Infile on 2024-05-17 Submitted works <1%
229	Universidad Adolfo Ibáñez on 2024-05-26 Submitted works <1%
230	Universidad Cesar Vallejo on 2023-07-06 Submitted works <1%
231	Universidad Internacional de la Rioja on 2021-07-23 Submitted works <1%
232	Universidad Internacional de la Rioja on 2023-05-18 Submitted works <1%
233	Universidad Internacional de la Rioja on 2023-06-02 Submitted works <1%
234	Universidad Internacional de la Rioja on 2024-05-03 Submitted works <1%
235	Universidad Internacional de la Rioja on 2024-05-12 Submitted works <1%
236	Universidad Internacional de la Rioja on 2024-06-09 Submitted works <1%

Descripción general de fuentes

Reporte de similitud	
237	<p>Universidad Nacional San Agustín on 2016-06-19</p> <p>Submitted works</p> <p><1%</p>
238	<p>Universidad Ricardo Palma on 2023-12-28</p> <p>Submitted works</p> <p><1%</p>
239	<p>Universidad San Francisco de Quito on 2013-11-29</p> <p>Submitted works</p> <p><1%</p>
240	<p>Universidad San Francisco de Quito on 2021-12-21</p> <p>Submitted works</p> <p><1%</p>
241	<p>Universidad San Ignacio de Loyola on 2024-04-27</p> <p>Submitted works</p> <p><1%</p>
242	<p>Universidad San Marcos on 2023-03-20</p> <p>Submitted works</p> <p><1%</p>
243	<p>Universidad TecMilenio on 2024-01-24</p> <p>Submitted works</p> <p><1%</p>
244	<p>Universidad de Chile on 2021-01-08</p> <p>Submitted works</p> <p><1%</p>
245	<p>Universidad de las Islas Baleares on 2024-01-26</p> <p>Submitted works</p> <p><1%</p>
246	<p>Universidad del Istmo de Panamá on 2024-03-29</p> <p>Submitted works</p> <p><1%</p>
247	<p>University of the Andes on 2023-09-27</p> <p>Submitted works</p> <p><1%</p>
248	<p>administracion.uexternado.edu.co</p> <p>Internet</p> <p><1%</p>

Descripción general de fuentes

Reporte de similitud	
249	dcc.uchile.cl Internet <1%
250	fdocuments.es Internet <1%
251	repositorio.unaj.edu.pe Internet <1%
252	repositorio.unap.edu.pe Internet <1%
253	repositorio.upt.edu.pe Internet <1%
254	repositorio.usm.cl Internet <1%
255	repository.javeriana.edu.co Internet <1%
256	unasam on 2024-05-27 Submitted works <1%
257	uvadoc.uva.es Internet <1%
258	aecr29.unican.es Internet <1%
259	cjascience.com Internet <1%
260	clubensayos.com Internet <1%

Descripción general de fuentes

Institución de origen		Reporte de similitud
261	codewithc.com Internet	<1%
262	dspace.espol.edu.ec Internet	<1%
263	elprincipe.com.ar Internet	<1%
264	utdt.edu Internet	<1%
265	worldcat.org Internet	<1%
266	Corporación Universitaria Minuto de Dios, UNIMINUTO on 2023-09-17 Submitted works	<1%
267	Emigdio Marín-Enrriquez. "A statistical approach for modeling shallow (..." Crossref	<1%
268	Pontificia Universidad Catolica del Peru on 2007-04-20 Submitted works	<1%
269	Universidad Internacional de la Rioja on 2024-01-18 Submitted works	<1%
270	Universidad Internacional de la Rioja on 2024-06-10 Submitted works	<1%
271	Universidad La Gran Colombia on 2021-07-27 Submitted works	<1%
272	Universidad San Ignacio de Loyola on 2024-06-18 Submitted works	<1%

Descripción general de fuentes

Reporte de similitud	
273	<p>Universidad Tecnológica Centroamericana UNITEC on 2024-03-24</p> <p>Submitted works</p> <p><1%</p>
274	<p>University College London on 2017-09-11</p> <p>Submitted works</p> <p><1%</p>
275	<p>uncedu on 2024-01-10</p> <p>Submitted works</p> <p><1%</p>
276	<p>"Advances in Computing", Springer Science and Business Media LLC, ...</p> <p>Crossref</p> <p><1%</p>
277	<p>ITESM: Instituto Tecnológico y de Estudios Superiores de Monterrey o...</p> <p>Submitted works</p> <p><1%</p>
278	<p>Institución Tecnológica Metropolitana de Medellín on 2019-07-16</p> <p>Submitted works</p> <p><1%</p>
279	<p>Pontificia Universidad Catolica del Peru on 2009-10-06</p> <p>Submitted works</p> <p><1%</p>
280	<p>Universidad Carlos III de Madrid - EUR on 2024-06-12</p> <p>Submitted works</p> <p><1%</p>
281	<p>Universidad Internacional de la Rioja on 2024-05-10</p> <p>Submitted works</p> <p><1%</p>
282	<p>Universidad Nacional Abierta y a Distancia, UNAD,UNAD on 2022-05-27</p> <p>Submitted works</p> <p><1%</p>
283	<p>Universidad Nacional Hermilio Valdizan on 2022-12-02</p> <p>Submitted works</p> <p><1%</p>
284	<p>Universidad Nacional del Centro del Peru on 2018-10-23</p> <p>Submitted works</p> <p><1%</p>

Descripción general de fuentes

ANEXO 08

AUTORIZACIÓN DE PUBLICACIÓN



AUTORIZACIÓN DE PUBLICACIÓN DIGITAL Y DECLARACIÓN JURADA DEL TRABAJO DE INVESTIGACIÓN, TESIS, TRABAJO DE SUFICIENCIA PROFESIONAL O TRABAJO ACADÉMICO PARA OPTAR UN GRADO O TÍTULO PROFESIONAL

1. Autorización de Publicación: (Marque con una "X" según corresponda)

Bachiller		Título Profesional	X	Segunda Especialidad		Maestro		Doctor	
-----------	--	--------------------	---	----------------------	--	---------	--	--------	--

Ingrese los datos según corresponda.

Facultad/Escuela	ECONOMÍA
Escuela/Carrera Profesional	ECONOMÍA
Programa	
Grado que otorga	
Título que otorga	ECONOMISTA

2. Datos del (los) Autor(es): (Ingrese los datos según corresponda)

Apellidos y Nombres:	ALVAREZ FLORES JHON HARRINSON						
Tipo de Documento:	DNI	X	Pasaporte		C.E.		N° de Documento: 71302670
Correo Electrónico:	jh.alvarezflores@gmail.com						
Apellidos y Nombres:	ENRIQUEZ MONTES CRHISTIAN JHON						
Tipo de Documento:	DNI	X	Pasaporte		C.E.		N° de documento: 73600656
Correo Electrónico:	crhistianjhon7@gmail.com						
Apellidos y Nombres:	TINEO CRUZ RAFAELA CAROLINA						
Tipo de Documento:	DNI	X	Pasaporte		C.E.		N° de Documento: 77037513
Correo Electrónico:	rafaelaineo1@gmail.com						

3. Datos del Asesor: (Ingrese los datos según corresponda)

Apellidos y Nombres:	ALVARADO CHAVEZ CLAYTON						
Tipo de Documento:	DNI	X	Pasaporte		C.E.		N° de Documento: 22463672
ORCID ID:	0000-0003-3733-6272						

4. Datos de los Jurados: (Ingrese los datos según corresponda, primero apellidos luego nombres)

Presidente	CAICEDO DAVILA LIZARDO
Secretario	RAMOS CORNELIO EMIGIDIO
Vocal	MARTEL CARRANZA CHRISTIAN PAOLO
Vocal	
Vocal	
Accesitario	

5. Datos del Documento Digital a Publicar: (Ingrese los datos y marque con una "X" según corresponda)

Ingrese solo el año en el que sustentó su Trabajo de Investigación: (Verifique la Información en el Acta de Sustentación)	2024				
Modalidad de obtención del Grado Académico o Título Profesional: (Marque con X según corresponda)	Trabajo de Investigación	Tesis	X	Trabajo Académico	Trabajo de Suficiencia Profesional
Palabras claves	MODELO DE REDES NEURONALES	EFFECTIVIDAD DE MODELO	SERIES DE TIEMPO		
Tipo de acceso: (Marque con X según corresponda)	Abierto	X	Cerrado*	Restringido*	Periodo de Embargo
(*) Sustentar razón:					



6. Declaración Jurada: (Ingrese todos los datos requeridos completos)

Soy Autor (a) (es) del Trabajo de Investigación Titulado: *(ingrese el título tal y como está registrado en el Acta de Sustentación)*

"NIVELES DE EFECTIVIDAD DEL MODELO DE REDES NEURONALES EN EL ANÁLISIS DEL COMPORTAMIENTO Y PREDICCIÓN DEL PBI DE PERÚ: 1980 - 2021"

Mediante la presente asumo frente a la Universidad Nacional Hermilio Valdizán (en adelante LA UNIVERSIDAD), cualquier responsabilidad que pueda derivarse por la autoría, originalidad y veracidad del contenido del trabajo de investigación, así como por los derechos de la obra y/o invención presentada. En consecuencia, me hago responsable frente a LA UNIVERSIDAD y frente a terceros de cualquier daño que pudiera ocasionar a LA UNIVERSIDAD o a terceros, por el incumplimiento de lo declarado o que pudiera encontrar causas en los trabajos de investigación presentado, asumiendo toda la carga pecuniaria que pudiera derivarse de ello. Asimismo, por la presente me comprometo a asumir además todas las cargas pecuniarias que pudiera derivar para LA UNIVERSIDAD en favor de terceros con motivos de acciones, reclamaciones o conflictos derivados del incumplimiento de lo declarado o las que encontraren causa en el contenido del Trabajo de Investigación. De identificarse fraude, piratería, plagio, falsificación o que el trabajo haya sido publicado anteriormente; asumo las consecuencias y sanciones que de mis acciones se deriven, someténdome a las acciones legales y administrativas vigentes.

7. Autorización de Publicación Digital:

A través de la presente autorizo de manera gratuita a la Universidad Nacional Hermilio Valdizán a publicar la versión digital de este trabajo de investigación en su biblioteca virtual, repositorio institucional y base de datos, por plazo indefinido, consintiendo que con dicha autorización cualquier tercero podrá acceder a dichas páginas de manera gratuita pudiendo revisarla, imprimirla o grabarla siempre y cuando se respete la autoría y sea citada correctamente.

Apellidos y Nombres		Firma	
ALVAREZ FLORES JHON HARRINSON			
ENRIQUEZ MONTES CRHISTIAN JHON			
TINEO CRUZ RAFAELA CAROLINA			

FECHA: Cayhuayna, 1 de agosto del 2024

Nota:

- ✓ No modificar los textos preestablecidos, conservar la estructura del documento.
- ✓ Marque con una X en el recuadro que corresponde.
- ✓ Llenar este formato de forma digital, con tipo de letra calibri, tamaño de fuente 09, manteniendo la alineación del texto que observa en el modelo, sin errores gramaticales (recuerde las mayúsculas también se tildan si corresponde).
- ✓ La información que escriba en este formato debe coincidir con la información registrada en los demás archivos y/o formatos que presente, tales como: DNI, Acta de Sustentación, Trabajo de Investigación (PDF), Constancia de Similitud, Reporte de Similitud.
- ✓ Cada uno de los datos requeridos en este formato, es de carácter obligatorio según corresponda.
- ✓ Se debe de imprimir, firmar y luego escanear el documento (legible).