

FACULTAD DE INGENIERÍA

Carrera de **INGENIERÍA DE MINAS**

“TÉCNICAS DE PREDICCIÓN APLICADAS AL
ANÁLISIS DEL PRECIO DEL ORO: UN ENFOQUE
COMPARATIVO”

Tesis para optar al título profesional de:

INGENIERO DE MINAS

Forma: Artículo científico

Autores:

Percy Huaman Sedano

Oscar Ericsson Infantes Suarez

Asesor:

Mg. Josualdo Carlos Villar Quiroz

<https://orcid.org/0000-0003-3392-9580>

Trujillo - Perú

2024

JURADO EVALUADOR

Jurado 1 Presidente(a)	MARCO ANTONIO DIAZ DIAZ
	Nombre y Apellidos

Jurado 2	ELMER OVIDIO LUQUE LUQUE
	Nombre y Apellidos

Jurado 3	JOSUALDO CARLOS VILLAR QUIROZ
	Nombre y Apellidos

INFORME DE SIMILITUD

TÉCNICAS DE PREDICCIÓN APLICADAS AL ANÁLISIS DEL PRECIO DEL ORO: UN ENFOQUE COMPARATIVO

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	hdl.handle.net Fuente de Internet	6%
2	"Intelligent Sustainable Systems", Springer Science and Business Media LLC, 2024 Publicación	4%
3	Submitted to Universidad Privada del Norte Trabajo del estudiante	1%
4	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	1%
5	Submitted to National College of Ireland Trabajo del estudiante	1%
6	Submitted to Universidad Nacional de Trujillo Trabajo del estudiante	1%
7	repository.usta.edu.co Fuente de Internet	1%
8	ymerdigital.com Fuente de Internet	1%

DEDICATORIA

A mi esposa Betty, mis hijas Xiomara y Karime, por su apoyo indesmayable, su paciencia, motivación incansable, su perseverancia, y su fortaleza mostrada fueron el soporte primordial para salir adelante en mi formación ética, moral en lo personal como profesional.

Percy.

A mis padres Pedro Infantes Alva y Miriam Irene Suarez Coello porque ellos fueron el pilar fundamental en mis estudios, gracias a ellos pude realizar mi sueño.
Mis hermanos Deysi, Alan, Cinthia son mis verdaderos amigos.
Mi novia Jannett Narro Camacho por su apoyo incondicional y moralmente, a mi familia que siempre serán lo más importante que Dios me ha brindado.

Oscar.

AGRADECIMIENTO

A Dios por bendecirnos y guiar nuestro camino porque gracias a él pudimos lograr nuestros objetivos, por cumplir este ansiado sueño.

Agradecer a nuestra alma mater Universidad Privada Del Norte por la oportunidad de formar parte de la institución y salir un gran profesional, a los docentes que impartieron sus conocimientos, apoyo, comprensión y paciencia para seguir adelante.

A nuestra familia, por su apoyo incondicional y soporte durante nuestra vida personal, laboral y profesional.

Tabla de Contenido

JURADO EVALUADOR	2
INFORME DE SIMILITUD	3
DEDICATORIA	4
AGRADECIMIENTO	5
INDICE DE FIGURAS	7
INDICE DE TABLAS	8
RESUMEN	9
CAPÍTULO I: INTRODUCCIÓN	10
CAPÍTULO II: METODOLOGÍA	11
CAPÍTULO III: RESULTADOS	17
CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES	19
REFERENCIAS	20

INDICE DE FIGURAS

Fig. 1. Flujograma del proceso	11
Fig. 2. Matriz de correlación de Pearson	13

INDICE DE TABLAS

Tabla 1. Resultados de Modelados para predicción de precio del Oro..... 15

Tabla 2. Resultados de predicción precio del Oro..... 16

RESUMEN

En este estudio, abordamos el desafío de desarrollar un modelo preciso y confiable para predecir el precio del oro. Nuestro objetivo principal es analizar y comparar diferentes enfoques, como los modelos de regresión lineal, Support Vector Regression y Árboles de regresión, para determinar cuál de ellos ofrece la mejor precisión en la predicción del precio del oro. A través de una exhaustiva revisión bibliográfica y el análisis de datos históricos, buscamos identificar patrones y tendencias que permitan mejorar la capacidad predictiva del modelo. En el proceso de desarrollo, hemos empleado un flujo de trabajo riguroso y transparente, desde la definición del problema hasta la evaluación de los modelos mediante la división de datos en conjuntos de entrenamiento, validación cruzada y prueba. Nuestra metodología incluye la recopilación de datos de fuentes confiables y la preparación de los datos mediante la limpieza, exploración y transformación adecuada. Los resultados obtenidos hasta ahora muestran que el modelo de regresión lineal alcanza una métrica R^2 superior a 0.91, pero con un RMSE de 31.49 y un MAE de 17.75. Aunque este enfoque es simple y fácil de entender, necesitamos explorar otros métodos de estudio automático para mejorar la precisión y la predicción del precio del oro. Los hallazgos del estudio tendrán implicaciones significativas tanto para los inversores como para la industria, al proporcionar información valiosa para la resolución de decisiones informadas sobre inversiones en oro y gestión de riesgos, así como para la proyección de la producción y la maximización de recursos en la industria minera. En este estudio, abordamos el desafío de desarrollar un modelo preciso y confiable para predecir el precio del oro. Nuestro objetivo principal es analizar y comparar diferentes enfoques, como los modelos de regresión lineal, Support Vector Regression y Árboles de regresión, para determinar cuál de ellos ofrece la mejor precisión en la predicción del precio del oro. A través de una exhaustiva revisión bibliográfica y el análisis de datos históricos, buscamos identificar patrones y tendencias que permitan mejorar la capacidad predictiva del modelo. En el proceso de desarrollo, hemos empleado un flujo de trabajo riguroso y transparente, desde la definición del problema hasta la evaluación de los modelos mediante la división de datos en conjuntos de entrenamiento, validación cruzada y prueba. Nuestra metodología incluye la recopilación de datos de fuentes confiables y la preparación de los datos mediante la limpieza, exploración y transformación adecuada. Los resultados obtenidos hasta ahora muestran que el modelo de regresión lineal alcanza una métrica R^2 superior a 0.91, pero con un RMSE de 31.49 y un MAE de 17.75. Aunque este enfoque es simple y fácil de entender, necesitamos explorar otros métodos de estudio automático para mejorar la precisión y la predicción del precio del oro. Los hallazgos de este estudio tendrán implicaciones significativas tanto para los inversores como para la industria, al proporcionar información valiosa para la resolución de decisiones informadas sobre inversiones en oro y gestión de riesgos, así como para la programación de producción y optimización de recursos en la industria minera.

PALABRAS CLAVES: Machine Learning, Regression, Prediction.

CAPÍTULO I: INTRODUCCIÓN

La fluctuación del precio del oro desempeña un papel crucial en el contexto económico y financiero global. Durante mucho tiempo, este metal precioso ha sido considerado como un resguardo seguro para los inversionistas en momentos de perplejidad económica y volatilidad en los mercados [1]. Su valor intrínseco y su constante demanda en industrias como la joyería y la electrónica hacen que el precio del oro sea un indicador importante de la estabilidad económica y las tendencias del mercado [2-3].

La capacidad de predecir con precisión el precio del oro se ha convertido en un desafío crucial para inversores, empresas y analistas financieros en la actualidad. El mercado del oro está sujeto a una gran volatilidad, lo que significa que los precios pueden examinar cambios significativos en periodos cortos de tiempo [4-5]. Además, factores económicos globales, como las condiciones macroeconómicas, la estabilidad política y las tasas de interés, tienen un golpe directo en el precio del oro.

Asimismo, la demanda global de oro también juega un papel fundamental en la decisión de su precio. El oro es considerado un activo seguro en tiempos de perplejidad económica y política, lo que significa que la demanda de este metal precioso puede aumentar en momentos de crisis [6]. Por otro lado, la disponibilidad y la producción mundial de oro también influyen en su precio, ya que una oferta limitada puede impulsar su valor al alza [7-8].

El desarrollo del modelo de predicción preciso del precio del oro tiene implicaciones significativas tanto para los inversores como para la industria. Los inversores pueden utilizar estas predicciones para dictaminar decisiones informadas sobre sus inversiones en oro y ajustar sus estrategias en consecuencia. Con un modelo confiable, podrán identificar oportunidades de compra y venta, así como gestionar de manera más efectiva los riesgos asociados a la inversión en este metal precioso [9-11].

Además, las empresas mineras y los actores de la industria pueden beneficiarse al comprender las tendencias y los factores clave que influyen en el precio del oro. Esto les permitirá tomar decisiones más fundamentadas en la programación de la producción, la evaluación de proyectos mineros y la gestión de riesgos. Al tener una idea más precisa de las proyecciones futuras del precio del oro, podrán optimizar sus operaciones y recursos, lo que conduce a una mayor eficiencia y rentabilidad.

En este estudio, nos enfrentamos al desafío de desarrollar un modelo preciso y confiable de predicción del precio del oro. Nuestro objetivo principal es analizar y comparar diferentes enfoques, como los modelos de regresión lineal, Support Vector Regression y Árboles de regresión, para determinar cuál de ellos ofrece la mejor precisión en la predicción del precio del oro. A través de una exhaustiva revisión bibliográfica y el análisis de datos históricos, buscamos identificar patrones y tendencias que permitan mejorar la capacidad predictiva del modelo.

CAPÍTULO II: METODOLOGÍA

Una vez establecidos los fundamentos teóricos y los datos relevantes, se procedió al desarrollo de un flujograma detallado que describe las etapas necesarias para generar los modelos predictivos específicos para la estimación del precio del oro. Este flujograma se basó en la revisión de trabajos similares y se diseñó de manera intuitiva y fácil de entender. Además, se proporcionó una descripción de las herramientas utilizadas durante el proceso, asegurando así la transparencia del estudio.

En la siguiente fase, se desarrollaron los modelos predictivos para la estimación del precio del oro. Los resultados obtenidos fueron sometidos a un exhaustivo análisis para evaluar la eficacia de los modelos y su capacidad para realizar predicciones precisas en relación al precio del oro.

Como resultado de esta metodología de trabajo, se espera obtener conclusiones significativas que contribuyan al análisis del precio del oro y a la aplicación de técnicas de predicción en este contexto. El enfoque cuantitativo, exploratorio y correlacional adoptado en esta investigación permitirá ampliar el conocimiento sobre la efectividad de los diferentes modelos predictivos disponibles y su aplicabilidad en el análisis del precio del oro.

2.1 Flujograma de trabajo

Se ha elaborado un flujograma basado en la revisión minuciosa de la literatura y estudios previos, con el propósito de guiar el mecanismo de desarrollo de modelos predictivos utilizando técnicas de estudio supervisado. En este artículo, se presentarán en detalle los aspectos de dicho flujograma (see **¡Error! No se encuentra el origen de la referencia.**), y se aplicará a casos de ejemplo específicos en la investigación.

Es importante destacar que el flujograma establece un orden inicial para el desarrollo de los modelos con algoritmos de machine learning. No obstante, es común que se produzca interacción entre los diferentes pasos una vez obtenido un resultado preliminar, con el objetivo de mejorar y lograr el resultado deseado. Esto resalta la flexibilidad y adaptabilidad inherentes al proceso de desarrollo de modelos predictivos.

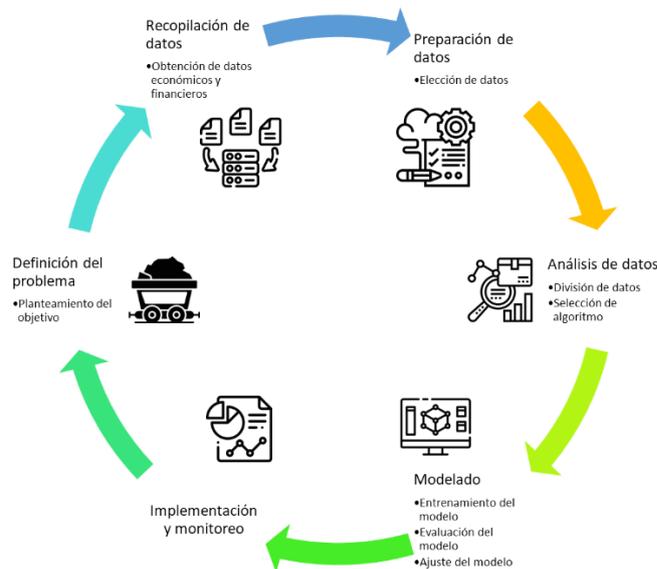


Fig. 1. Flujograma del proceso.

- **Definición del problema.** es fundamental identificar la técnica de aprendizaje automático (machine learning) que se empleará para abordar un problema específico. Este paso resulta crucial, ya que contribuye a establecer las variables necesarias para los pasos subsiguientes del proceso.

La categorización del problema se lleva a cabo en dos fases. En primer lugar, se realiza la categorización basada en la entrada de datos. Si los datos disponibles cuentan con etiquetas que indican la respuesta deseada, nos encontramos ante un problema de estudio supervisado. Si los datos no están etiquetados y el objetivo es descubrir patrones o estructuras, nos enfrentamos a un problema de estudio no supervisado. Por otro lado, la intención es optimizar una función objetivo mediante interacciones con el entorno, estamos ante un problema de estudio por refuerzo. En segundo lugar, se procede a categorizar el problema según la salida del modelo. Si la salida deseada es un valor numérico, nos encontramos ante el problema de regresión. Si la salida que se espera corresponde a clase o categoría, nos referimos a un problema de clasificación. Si el objetivo es agrupar las entradas en diferentes conjuntos, nos enfrentamos a un problema de agrupamiento. Por último, si buscamos identificar anomalías o valores atípicos en los datos, estamos tratando con un problema de detección de anomalías.

En esta investigación, se utilizó el modelo de aprendizaje supervisado para predecir el precio del oro, debido a la disponibilidad de datos constantes y conocidos tanto para entrada como de salida. El ejercicio se clasifica como problema de regresión, ya que se busca predecir un valor numérico. Se consideran diversas variables predictoras, como el indicador del precio del dólar, la tasa de interés de la Reserva Federal de los Estados Unidos, el resultado interno bruto de Estados Unidos, la producción mundial de oro y otros factores relevantes. La métrica de medición utilizada será el RMSE.

- **Recopilación de datos.** Durante la segunda fase del proceso, se emprendió la tarea de recopilar los datos necesarios para el estudio. Este proceso involucró la recolección de información a lo largo de los últimos 5 años, con una frecuencia interdiaria, lo cual supuso un desafío debido a la limitada disponibilidad de datos con esa frecuencia en algunos informes. La recopilación de datos fue realizada a partir de diversas fuentes confiables, y se priorizó la selección de aquellos que eran relevantes y pertinentes del estudio. Estos datos fueron cuidadosamente obtenidos y posteriormente cargados a una base de datos específica para el análisis posterior.

Es importante destacar que la elección rigurosa de las fuentes de datos y la consistencia en la recopilación de información son aspectos muy fundamentales en garantizar la calidad y confiabilidad de los datos empleados en el estudio. El propósito principal de esta fase fue crear un conjunto de datos completo y coherente que permitiera realizar un análisis exhaustivo y preciso en etapas posteriores del proyecto. Al superar los retos relacionados con la frecuencia de datos y llevar a cabo un proceso meticuloso de recopilación y selección, se sentaron las bases para un estudio robusto y confiable sobre la predicción del precio del oro.

- **Preparación de datos.** Inicialmente, se lleva a cabo un proceso de limpieza de datos, donde se identifican y manejan los valores atípicos, los datos faltantes o inconsistentes, y cualquier otro problema que pueda dañar la totalidad de los datos. Esto implica realizar operaciones como la imputación de valores faltantes o la eliminación de registros duplicados.

A continuación, se realiza una exploración y transformación de los datos. Esto implica realizar análisis estadísticos y visuales para comprender la distribución y correlación de las variables, identificar posibles relaciones no lineales o patrones ocultos, y seleccionar las características más relevantes para la construcción del modelo predictivo. Además, se pueden aplicar técnicas de escalado, normalización o codificación de variables categóricas para asegurar la comparabilidad y adecuado procesamiento de los datos por parte de los algoritmos de aprendizaje instantáneo.

En transcurso de esta etapa, se emplea la tabla de correlación de Pearson como una herramienta eficaz para analizar la relación entre las variables en el estudio de precios del oro. Después de recopilar y preparar los datos, se comienza a calcular la matriz de correlación de Pearson. Esta matriz se presenta como una tabla cuadrada en la que las filas y columnas representan las diferentes variables consideradas en el estudio. Cada celda de la matriz muestra el factor de correlación de Pearson, que indica la fuerza y la dirección de relación entre las variables correspondientes.

Al analizar una tabla de correlación de Pearson, puede identificar patrones y tendencias en sus datos. Un coeficiente de correlación cercano a 1 indica una fuerte correlación positiva, lo que significa que las variables tienden a aumentar o disminuir al mismo tiempo. Un coeficiente cercano a -1 indica nuevamente una fuerte correlación negativa, lo que sugiere que las variables tienen una relación inversa. Un coeficiente cercano a 0 indica una correlación débil o nula. Al examinar la tabla de correlación, es

posible identificar aquellas variables que están altamente correlacionadas con el precio del oro. Estas variables pueden ser consideradas como predictores potenciales en el modelo de predicción (see 2).



Fig. 2. Matriz de correlación de Pearson.

- Análisis de datos.** Al analizar el proceso de datos, se enfrenta el desafío de pronosticar series de tiempo, tomando en consideración las características de las variables y del problema en cuestión. En este estudio, se busca predecir el precio del oro, el cual actúa como la variable dependiente, mientras que otras variables se consideran como variables independientes. Esto implica la aplicación de algoritmos de aprendizaje automático que utilizan múltiples datos de entrada para realizar el pronóstico. Es fundamental mantener el orden temporal de las variables durante todo el análisis, ya que las relaciones y patrones en los datos pueden estar influenciados por cambios a lo largo del tiempo.

Posteriormente, se lleva a cabo la división de los datos en tres conjuntos: entrenamiento, validación cruzada y pruebas. El conjunto de entrenamiento se utiliza para practicar los modelos, permitiendo que aprendan las normas y relaciones presentes en los datos históricos. El conjunto de validación cruzada se utiliza para afinar los modelos y optimizar sus parámetros, para garantizar así el mejor rendimiento. Por último, el conjunto de prueba se utiliza para evaluar el rendimiento final de los modelos desarrollados, proporcionando una medida objetiva de su capacidad de generalización a datos no vistos previamente.

La división de los datos se realiza de manera estratégica, asignando aproximadamente el 75% de los datos al conjunto de entrenamiento, mientras que el 25% restante se divide equitativamente entre el conjunto de validación cruzada y el conjunto de prueba. Esta distribución garantiza que los modelos sean entrenados con una cantidad

suficiente de datos para capturar las complejidades del problema, al mismo tiempo que se reservan datos independientes para evaluar su desempeño de manera imparcial. Esta metodología de división de datos contribuye a obtener modelos robustos y confiables que puedan realizar pronósticos precisos del precio del oro en futuras observaciones.

- **Modelado.** Se presentan tres modelos diferentes para comparar su desempeño en relación en la base de datos recopilada. A continuación, se describirá el proceso de entrenamiento de cada modelo con los algoritmos seleccionados.

Modelo lineal. Se utiliza un modelo de regresión lineal para evaluar el rendimiento inicial de los algoritmos de aprendizaje automático en una nueva base de datos. Además, podrá comprender mejor los datos disponibles y definir su preprocesamiento o trabajo posterior sobre ellos. Este modelo es simple, fácil de entender y no requiere mayor personalización como otros algoritmos. Después de intentar optimizar las variables utilizando métodos como PCA, filtros y funciones RFE recursivas, se decidió utilizar todas las variables predictoras ya que los resultados obtenidos fueron los mejores.

El modelo lineal proporcionó resultados aceptables con una métrica R^2 superior a 0.91, pero con un RMSE de 31.49 y un MAE de 17.75. Aunque este algoritmo es simple y fácil de usar, intentaremos lograr mejores resultados con los algoritmos seleccionados restantes.

Support Vector Regressor. El modelo SVR es más complejo que el modelo lineal, ya que requiere ajustes en sus hiperparámetros. Para ajustar estos parámetros, se utilizó la validación cruzada con una técnica de búsqueda en cuadrícula. Se probaron diferentes valores de los parámetros C y gamma para cada uno de los Kernels, y se seleccionaron los valores que obtuvieron la puntuación más alta.

Los resultados obtenidos indicaron que los parámetros óptimos para el SVR fueron: C = 1000, gamma = 0.01, ϵ = 0.01, con un puntaje de optimización de 0.96. Este modelo mostró un ajuste mucho mejor que el modelo lineal y obtuvo un RMSE de 22.50 después de la optimización de sus hiperparámetros.

Árbol de regresión. El modelo de árbol de decisión tiene ventajas como su fácil interpretación, la capacidad de manejar datos no distribuidos de manera específica, requerir menos limpieza de datos y no verse afectado por valores atípicos. Sin embargo, puede presentar sobreajuste si no se controla su crecimiento.

Para evitar el sobreajuste, se utilizaron técnicas de pre-poda (pre-pruning) y post-poda (post-pruning). La pre-poda se aplicó ajustando los hiperparámetros del árbol de decisión antes del entrenamiento, utilizando la técnica GridSearchCV. Se exploraron diferentes valores de los hiperparámetros max_depth, max_samples_leaf y max_samples_split.

La post-poda se aplicó después de construir el árbol de decisión, eliminando ramas no significativas utilizando la técnica de `cost_complexity_pruning`. Se determinó el valor óptimo de `ccp_alpha` y se podaron las ramas del árbol de decisión.

Se obtuvieron resultados mejorados utilizando las técnicas de pre-poda y post-poda en comparación con el modelo inicial. El rendimiento en los datos de prueba fue significativamente mejor. El modelo de árbol de regresión mostró un buen ajuste con una métrica R^2 de 0.95, un RMSE de 23.14 y un MAE de 13.22. Se evitó el sobreajuste mediante las técnicas de pre-poda y post-poda.

CAPÍTULO III: RESULTADOS

La evaluación de los modelos para predecir el precio del oro se realiza mediante diferentes métricas, como el Error Absoluto Medio (MAE), el Error Cuadrático Medio (RMSE) y el Puntaje R². Estas métricas proporcionan una medida de la precisión y el ajuste de los modelos con respecto a los datos de prueba.

La Tabla 1 muestra los resultados finales obtenidos en la elaboración de los varios modelos de predicción del precio del oro. Los modelos evaluados incluyen Regresión Lineal, Árbol de Regresión y SVR (Support Vector Regression). Estos modelos fueron seleccionados debido a su capacidad para abordar la complejidad del problema de predicción.

Tabla 1. Resultados de modelos para la predicción del precio de Oro.

Modelo	MAE	RMSE
Regresión Lineal	17.75	31.49
Árbol de Regresión	9.32	14.32
SVR	4.63	5.29

No obstante, para lograr estos resultados, es necesario realizar un análisis exhaustivo de los pasos del flujograma explicado en el capítulo correspondiente, especialmente el primer paso que implica en comprender y enmarcar correctamente el problema a resolver, ya que es crucial para los pasos siguientes y, finalmente para el rendimiento del modelo.

En la fase de implementación, el modelo generado se aplica al negocio o proceso para el cual fue desarrollado. En esta etapa, se seleccionan algunas muestras de datos nuevos, que no se utilizaron durante el entrenamiento del modelo, y se utilizan para realizar predicciones del precio del oro. Las muestras de datos seleccionadas representan escenarios o situaciones nuevas en las que se desea conocer el valor pronosticado del precio del oro. Estas muestras pueden estar compuestas por variables relevantes, como indicadores económicos, factores políticos o eventos específicos que puedan influir en el precio del oro.

Utilizando el modelo desarrollado, se aplican estos datos de entrada y se obtienen las predicciones correspondientes. Estas predicciones se basan en el aprendizaje realizado por el modelo durante la fase de entrenamiento, donde se identificaron patrones y relaciones entre las variables para hacer estimaciones precisas. Los resultados de estas predicciones se recopilan y se presentan en la tabla 2 que resume los valores pronosticados del precio del oro para las muestras de datos seleccionadas. Esta tabla

permite evaluar el desempeño del modelo en la predicción de precios futuros y brinda información valiosa para la toma de decisiones estratégicas.

Tabla 2. Resultados de la predicción del precio del Oro.

Modelo	Precio Real	Predicción
1	1361.40	1362.25
2	1360.10	1358.13
3	1329.70	1329.54
4	1362.50	1361.79
5	1366.30	1367.05
6	1329.60	1330.20
7	1318.30	1317.76
8	1316.40	1318.50
9	1314.30	1314.72
10	1307.50	1306.84

Es importante destacar la importancia de los predictores en la variación del precio del oro. Según el análisis realizado, la inflación de Estados Unidos y el índice del precio del dólar son variables significativas que influyen en el precio del oro. Otros factores como la oferta y demanda, la producción mundial de oro y los costos de producción también desempeñan un papel importante en la fluctuación de las cotizaciones.

CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES

En conclusión, en este estudio se llevó a cabo la predicción del precio del oro utilizando diferentes modelos basados en algoritmos de machine learning. Se evaluaron y compararon los resultados obtenidos con métricas como el Error Absoluto Medio (MAE) y el Error Cuadrático Medio (RMSE).

Los modelos utilizados incluyeron Regresión Lineal, Árbol de Regresión y SVR (Support Vector Regression). Tras el análisis de los resultados, se determinó que el modelo SVR fue el que presentó el mejor desempeño, con un puntaje MAE de 4.63 y un RMSE de 5.29 en la prueba. Estos resultados demuestran la eficacia de los algoritmos de machine learning para resolver problemas de regresión complejos, como la predicción del precio del oro.

Además, se han identificado variables importantes que influyen en la variación del precio del oro, como la inflación estadounidense, el índice de precios del dólar, la oferta y demanda, la producción mundial de oro y los costos de producción. Estos factores son clave para comprender las fluctuaciones en el precio y brindan información valiosa para la toma de decisiones estratégicas en industrias como los gobiernos, los bancos y las empresas mineras.

En términos generales, los modelos predictivos desarrollados en este estudio superaron a los enfoques tradicionales basados en estadísticas clásicas. Los modelos de machine learning ofrecen un potencial significativo para su implementación en diferentes industrias y sectores interesados en la predicción del precio del oro.

REFERENCIAS

1. Cauna C., Yoselin Y. "La evolución del precio del oro y su relación con el rendimiento de la Bolsa de Valores de Lima-Perú, periodo 2017-2021." (2022).
2. Muñoz N., and García E. "Redes neuronales artificiales aplicadas a la predicción del precio del oro." (2016).
3. Vidya, G. S., and V. S. Hari. "Gold price prediction and modelling using deep learning techniques." 2020 IEEE Recent Advances in Intelligent Computational Systems (RAICS). IEEE, 2020.
4. Toraman, Cengiz, Cagatay Basarir, and Mehmet Fatih Bayramoglu. "Determination of factors affecting the price of gold: A study of MGARCH model." pp. 37–50. Business and economics research journal 2.4 (2011).
5. Wenxin D, and Schreger J. "Sovereign risk, currency risk, and corporate balance sheets." Harvard Business School BGIE Unit Working Paper (2016).
6. Manjula, K. A., and P. Karthikeyan. "Gold price prediction using ensemble based machine learning techniques." 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI). IEEE, 2019.
7. Vidya, G. S., and V. S. Hari. "Gold price prediction and modelling using deep learning techniques." 2020 IEEE Recent Advances in Intelligent Computational Systems (RAICS). IEEE, 2020.
8. Neri, F. "Combining machine learning and agent based modeling for gold price prediction." Artificial Life and Evolutionary Computation: 13th Italian Workshop, WIVACE 2018, Parma, Italy, September 10–12, 2018, Revised Selected Papers 13. Springer International Publishing, 2019.
9. Hafezi, R, and Akhavan, A. "Forecasting gold price changes: Application of an equipped artificial neural network.", pp.71-82. AUT Journal of Modeling and Simulation 50.1 (2018).
10. Shafiee, Shahriar, and Erkan Topal. "An overview of global gold market and gold price forecasting." pp178-189 Resources policy 35.3 (2010).
11. Han, Ai, et al. "An interval method for studying the relationship between the Australian dollar exchange rate and the gold price." pp. 121-132 Journal of Systems Science and Complexity 25 (2012)