

Development of Predictive Regression Models in the Copper Mining Industry Using Artificial Neural Networks (ANN)

César Ramón Vásquez Torrel¹, Daniel Alejandro Alva Huamán¹

¹ Universidad Privada del Norte (UPN), Cajamarca, Perú cesar.vasquez@upn.edu.pe, daniel.alva@upn.edu.pe

Abstract– *The present research focused on the development of artificial intelligence (AI) tools within the mining sector, specifically through predictive regression models, with an emphasis on the copper industry. This study adopted a quantitative and exploratory approach, enabling the development of models using various features of artificial neural networks (ANN) through Machine Learning algorithms, based on historical data in both cases. The main objective of this study was to develop predictive regression models in the copper mining industry using artificial neural networks (ANN). In this context, forecasts were made for the future price of copper and the capital cost of open-pit copper mines. The results indicate that it was possible to estimate, with an acceptable degree of accuracy, both the future price of copper and the mining capital cost for open-pit copper mines. In the first case, a model was developed using the TensorFlow-based Deep Learning ANN technique for the "REDPC_17" test. A 7-day forecast was achieved with an acceptable margin for the three networks—LSTM, GRU, and CNN—resulting in an MSE of 2.6621e-04, 5.8286e-04, and 3.0642e-04, respectively. This led to an average percentage error of 7.9342% for the CNN network, which proved to be the best performer in the test. In the second case, a model was developed using the Scikit-Learn MLPRegressor ANN technique for the "REDES_20" test. This model achieved the best performance in estimating CAPEX, with a determination coefficient (R^2) of 0.00960 and an MSE of 0.8674.*

KEYWORDS: *Artificial Intelligence, Artificial Neural Network, Forecasting, Copper, Capital Cost, Mining Industry*

Desarrollo de modelos predictivos de regresión en la industria minera cuprífera mediante el uso de redes neuronales artificiales (RNA)

César Ramón Vásquez Torrel¹, Daniel Alejandro Alva Huamán¹

¹ Universidad Privada del Norte (UPN), Cajamarca, Perú cesar.vasquez@upn.edu.pe, daniel.alva@upn.edu.pe

Resumen– La presente investigación se enfocó en el desarrollo de herramientas de inteligencia artificial (IA) dentro del ámbito minero, específicamente a través de modelos predictivos de regresión, centrándose en la industria del cobre. Este estudio adoptó un enfoque cuantitativo y exploratorio, lo que permitió el desarrollo de modelos utilizando diversas características de redes neuronales artificiales (RNA) mediante algoritmos de Machine Learning, basándose en datos históricos para ambos casos. El principal objetivo de este estudio fue desarrollar modelos predictivos de regresión en la industria minera del cobre utilizando redes neuronales artificiales (RNA). En este contexto, se realizaron pronósticos para el precio futuro del cobre y el costo de capital de las minas de cobre a cielo abierto. Los resultados obtenidos indican que se logró estimar con un grado aceptable de certeza tanto el precio futuro del cobre como el costo de capital minero para las minas cupríferas a cielo abierto. En el primer caso, se desarrolló un modelo utilizando la técnica de RNR Deep Learning de TensorFlow para la prueba "REDPC_17". Se logró un pronóstico para 7 días en el futuro con un margen aceptable para las tres redes LSTM, GRU y CNN, obteniendo un ECM de $2.6621e-04$, $5.8286e-04$ y $3.0642e-04$, respectivamente. Esto resultó en un error porcentual promedio del 7.9342% para la red CNN demostrando ser la mejor para el ensayo. En el segundo caso, se desarrolló un modelo utilizando la técnica de RNA del tipo MLPRegressor de Scikit-Learn para la prueba "REDES_20". Este modelo tuvo el mejor desempeño en la estimación del CAPEX, con un coeficiente de determinación (R^2) de 0.00960 y un ECM de 0.8674.

Palabras Claves: *Inteligencia Artificial, Red Neuronal Artificial, Pronóstico, Cobre, Costo de Capital, Industria Minera*

I. INTRODUCCIÓN

El entorno actual es volátil y desafiante para las empresas mineras, que deben mantener costos bajos, automatizar procesos y reducir la dependencia de mano de obra [1]. Dado que el precio de los metales fluctúa por múltiples factores, es esencial aplicar metodologías que aumenten la eficiencia y reduzcan costos [2]. Se busca soluciones que disminuyan la incertidumbre y permitan tomar decisiones informadas [3].

La minería, al estar llena de incertidumbre, requiere modelos predictivos que optimicen la toma de decisiones y minimicen riesgos [4]. Las empresas mineras han adoptado capacidades analíticas para mejorar su rentabilidad, reducir costos y gestionar mejor los riesgos [5].

El cobre, con gran importancia industrial, es clave para Perú, el segundo mayor productor mundial [6]. La inteligencia artificial (IA) se plantea como herramienta para mejorar la precisión de los modelos predictivos [7]. El precio de los metales depende de la oferta y demanda global, especialmente influenciado por China [8].

El costo de capital es crucial para determinar la viabilidad de proyectos mineros [9], y las tecnologías como Big Data y Machine Learning han optimizado procesos en la industria minera [10]. Un estudio de Accenture destaca que el 82% de los ejecutivos mineros planean aumentar su inversión en tecnologías digitales [11]. Un ejemplo de éxito es la Compañía Minera Antamina, que ha mejorado su producción de cobre mediante el uso de IA [12].

II. MATERIALES Y MÉTODOS

A. Recolección de los datos

La recopilación de datos se realizó a partir de fuentes secundarias y bases de datos públicas y científicas, garantizando información confiable para el desarrollo de los modelos predictivos.

Para la investigación, se seleccionaron dos grandes conjuntos de datos:

- Para el precio del cobre: Se recopiló información de *Yahoo Finance*, incluyendo variables macroeconómicas relevantes como:
 - Producto Bruto Interno (PBI) de EE.UU. y China.
 - Índice de Gerentes de Compras (PMI) de EE.UU. y China.
 - Tipo de cambio dólar-yuan y dólar-euro.
 - Precio del oro.

- Precio del petróleo.
- Tasa de inflación de China.
- Variación histórica del precio del cobre

- Para el costo de capital minero (CAPEX): Se utilizaron datos de 53 proyectos mineros de minas cupríferas a cielo abierto, obtenidos de estudios científicos realizados por Nourali & Osanloo [13] [14]. Las variables incluidas fueron:

- Producción anual de la mina (MineAP).
- Producción anual del molino (MillAP).
- Stripping Ratio (SR).
- Ley media de reserva (RMG).
- Vida útil de la mina (LOM).

B. Etapa de preprocesamiento

El preprocesamiento de datos fue una etapa fundamental en la investigación, ya que permitió garantizar la calidad y la utilidad de la información antes de su uso en los modelos predictivos. Se llevaron a cabo las siguientes tareas:

Limpieza de datos. - Para evitar sesgos y errores en los modelos de predicción, se realizó un proceso de depuración de datos, asegurando que cumplieran con ciertos criterios de calidad:

- Eliminación de valores atípicos: Se descartaron registros con valores extremadamente altos o bajos que podrían afectar la precisión del modelo.
- Verificación de consistencia: Se comprobaron los datos para evitar duplicaciones y errores de formato.

Normalización y estandarización de datos. - Se empleó la técnica de MinMaxScaler de la biblioteca Scikit-Learn para transformar los datos en un rango entre 0 y 1, facilitando su procesamiento por parte de los algoritmos de Machine Learning.

Segmentación y estructuración de los datos. - Para evaluar el rendimiento de los modelos, se dividieron los datos en dos conjuntos:

- 80% para entrenamiento, permitiendo que los modelos aprendieran patrones a partir de los datos históricos
- 20% para validación y prueba, objetivo de evaluar la capacidad predictiva y la generalización de los modelos




Figura 1: División de los datos en conjuntos de entrenamiento y prueba para ambos modelos

C. Trabajo de programación

La implementación del modelo predictivo se realizó mediante programación en Python, utilizando diversas bibliotecas especializadas en Machine Learning y procesamiento de datos.

Se emplearon las siguientes herramientas:

- Scikit-Learn: Para la construcción del modelo MLP Regressor, utilizado en la predicción del CAPEX.
- TensorFlow y Keras: Para la implementación de redes neuronales profundas, incluyendo LSTM, CNN y GRU, usadas en la predicción del precio del cobre.
- Pandas y NumPy: Para la manipulación y análisis de datos.
- Matplotlib y Seaborn: Para la visualización de datos y análisis exploratorio.

Los modelos predictivos fueron desarrollados siguiendo estos pasos:

1. Carga de datos y preprocesamiento. - Se importaron los datos recopilados y se aplicaron los procedimientos de limpieza y normalización
2. Validación del modelo. - Se midió la precisión utilizando métricas como Error Cuadrático Medio (MSE) y Coeficiente de Determinación (R^2)
3. Predicción de nuevos valores. - Se usaron los modelos entrenados para estimar el precio futuro del cobre y el CAPEX de proyectos mineros.

III. Resultados y discusión

Se desarrollaron dos modelos principales para abordar la problemática planteada. A continuación, se presentan los hallazgos obtenidos tras la aplicación de los modelos predictivos de regresión en la industria minera cuprífera:

1. Modelo de predicción del precio del cobre:

En la primera fase del estudio, se desarrollaron modelos de regresión utilizando múltiples variables macroeconómicas y financieras, como el PBI de EE.UU. y China, el PMI, la tasa de inflación, el tipo de cambio y el precio del oro y petróleo, entre otras. Al analizar los resultados de estos modelos, se encontró que muchas variables presentaban una baja correlación con el precio del cobre, disminuyendo su impacto predictivo. Además, se identificó un problema de desajuste en la frecuencia de los datos, ya que algunas de estas variables estaban disponibles de forma mensual o trimestral, mientras que el precio del cobre se registraba diariamente. Esto generó inconsistencias en la serie de datos, dificultando el entrenamiento de los modelos




Figura 2: Pronostico usando Scikit – Learn para varios días en el futuro con variables adicionales

Ante esta situación, se optó por emplear únicamente la variación histórica del precio del cobre, transformando la predicción en un problema de series temporales. Esto significa que el modelo se enfocó en identificar patrones y tendencias dentro de los propios valores pasados del precio del cobre, en lugar de depender de factores macroeconómicos externos. En la práctica, este enfoque permite capturar la dinámica intrínseca del mercado del cobre, ya que su comportamiento suele estar influenciado por su propia estructura de precios históricos, los cuales reflejan indirectamente efectos de oferta y demanda, eventos económicos globales y especulación en los mercados de futuros

Para abordar esta problemática, se utilizaron modelos avanzados de redes neuronales profundas, específicamente LSTM (Long Short-Term Memory), CNN (Redes Neuronales Convolucionales) y GRU (Gated Recurrent Unit). Estos modelos han sido ampliamente utilizados en problemas de predicción de series temporales debido a su capacidad para reconocer patrones en secuencias de datos, filtrando la información relevante y minimizando la dependencia de variables externas.




Figura 3.- Estimación de precios de cierre diario del cobre con la red CNN

Los resultados obtenidos indicaron que la CNN fue el modelo más preciso lo que significa que su capacidad para predecir el precio del cobre a corto plazo de siete días en el futuro fue superior en comparación con las arquitecturas LSTM (EPP: 9.12%) y GRU (EPP: 8.45%). La CNN logró capturar mejor las fluctuaciones del precio del cobre, superando incluso a modelos comúnmente utilizados en series temporales, como LSTM.

	LSTM	GRU	CNN	REAL	Diferencia %_LSTM	Diferencia %_GRU	Diferencia %_CNN
0	3.835343	3.851568	3.864172	3.7660	6.934261	8.556771	9.817219
1	3.848554	3.878392	3.889487	3.7395	10.905433	13.889146	14.998722
2	3.862028	3.902766	3.921917	3.8180	4.402781	8.476543	10.391712
3	3.875937	3.927325	3.948750	3.9085	3.256321	1.882529	4.024982
4	3.889924	3.953499	3.997960	4.0185	12.857604	6.500101	2.053976
5	3.903739	3.977994	4.024221	4.0670	16.326118	8.900547	4.277897
6	3.917572	4.002178	4.054746	4.1545	23.692846	15.232229	9.975433

Tabla 1.- Resultados de las predicciones realizadas mediante redes neuronales recurrentes

Los resultados obtenidos indicaron que la CNN fue el modelo más preciso lo que significa que su capacidad para predecir el precio del cobre a corto plazo de siete días en el futuro fue superior en comparación con las arquitecturas LSTM (EPP: 9.12%) y GRU (EPP: 8.45%). La CNN logró capturar mejor las fluctuaciones del precio del cobre, superando incluso a modelos comúnmente utilizados en series temporales, como LSTM.

Nombre de Prueba	ECM
LSTM	2.6621e-04
CNN	3.0642e-04
GRU	5.8286e-04

Tabla 2.- Evaluación del ECM para las tres variantes

Los resultados obtenidos en la investigación refuerzan la hipótesis de que el precio del cobre está altamente influenciado por su propia evolución histórica, y que la incorporación de variables macroeconómicas adicionales no siempre mejora la capacidad predictiva de los modelos. Esto concuerda con estudios previos que sugieren que los mercados de commodities presentan comportamientos cíclicos y estacionales, donde los factores externos ya están implícitos en la dinámica del precio pasado

En comparación, el modelo de predicción del precio del cobre, basado en redes neuronales, como CNN, LSTM y GRU, mostró una mejor capacidad predictiva debido a su naturaleza de modelar comportamientos no lineales y de alta volatilidad, lo que concuerda con los trabajos de Hatayama & Tahara [15], que demostraron la efectividad de las redes neuronales en mercados de metales como el cobre. Las CNN fueron particularmente eficaces en la detección de patrones locales en el precio del cobre, lo que refleja un enfoque similar al de Alameer et al. [16] quienes combinaron redes neuronales y algoritmos genéticos para lograr mejores predicciones en precios

Los hallazgos de este estudio son consistentes con trabajos previos en la predicción del precio de metales usando técnicas de Machine Learning. Por ejemplo, Fosca Gamarra [8] encontró que los modelos basados en Support Vector Regression (SVR) podían predecir el precio del cobre con cierto grado de precisión, pero con limitaciones en la captura de patrones no lineales. En contraste, este estudio demuestra que el uso de redes neuronales profundas ofrece mejores resultados, con la CNN logrando el menor error porcentual (7.93%).

2. Modelo de predicción del costo de capital minero (CAPEX):

El modelo seleccionado para la predicción del costo de capital minero (CAPEX) fue un MLP Regressor (Perceptrón Multicapa, Multilayer Perceptron - MLP), implementado con la biblioteca Scikit-Learn en Python. Se eligió este modelo porque las redes neuronales artificiales (ANN) pueden capturar relaciones complejas y no lineales entre las variables de entrada y la variable objetivo.

Los resultados muestran que ambas curvas siguen una tendencia similar, lo que indica que el modelo captura correctamente los patrones de los datos y ofrece predicciones cercanas a los valores reales. Esto sugiere que la red neuronal ha logrado generalizar el comportamiento del CAPEX según las variables de entrada, permitiendo estimar su evolución en diferentes escenarios. Sin embargo, aunque se identifican las tendencias generales, persisten variaciones significativas en las predicciones individuales, lo que podría deberse a la sensibilidad del modelo a datos atípicos o a la falta de variables clave que afectan el costo de capital minero.




Figura 4.- Resultados para el pronóstico del CAPEX

La comparación entre los valores reales y estimados del CAPEX, revela que el modelo basado en MLP Regressor logra identificar una tendencia general en la evolución del costo de capital minero, pero aún presenta variaciones considerables en predicciones individuales. Por ejemplo, en el Caso 0, el modelo estimó un CAPEX de 4888.39 millones de dólares, mientras que el valor real fue de 5761.0 millones, con una diferencia de 872.61 millones. De manera similar, en el Caso 8, la estimación del modelo se alejó aún más del valor real, con una diferencia de 1087.84 millones. Estas discrepancias pueden deberse a múltiples factores, aunque el modelo logra capturar patrones de comportamiento en el CAPEX estas diferencias sugieren que su capacidad de predicción en casos específicos podría mejorar mediante la inclusión de más datos, el ajuste de pesos en la red neuronal o el uso de técnicas más avanzadas

N°	CAPEX REAL	CAPEX ESTIMADO	DIFERENCIA
0	5761.0	4888.392133	872.607867
1	944.0	555.503314	388.496686
2	3500.0	3762.796149	262.800000
3	1627.0	2334.282866	707.280000
4	5950.0	5258.291197	691.708803
5	1252.0	824.386519	427.613481
6	3300.0	3578.991152	278.990000
7	1806.0	2333.592416	527.590000
8	1983.0	895.156197	1087.843803
9	1844.0	1287.170641	556.829359
10	1650.0	1849.463103	199.460000

Tabla 3.- Evaluación del ECM para las tres variantes

Los resultados del modelo de predicción del **costo** de capital minero (CAPEX) indicaron que el desempeño del MLP Regressor fue significativamente bajo, con un coeficiente de determinación (R^2) de 0.0096 y un Error Cuadrático Medio (MSE) de 0.8674 para la mejor prueba denominada “REDES_020”. Estos valores reflejan que el modelo no pudo capturar correctamente la relación entre las variables independientes y el CAPEX, lo que sugiere que existen múltiples factores que no fueron considerados en el modelo o que el método de Machine Learning utilizado no fue el más adecuado para este problema.

Nombre de Prueba	ECM	R^2
REDES_002	0.7040614515216527	0.014997083764
REDES_008	0.777113866057482	0.0090977063737
REDES_015	0.854629278052330	0.1210548629 906
REDES_020	0.86740515866859	0.009604597856016

Tabla 4.- Resultados de las predicciones realizadas mediante MLP Regressor

El análisis de correlación reveló que la producción anual de la mina (MineAP) y del molino (MillAP) fueron las variables con mayor impacto en el CAPEX, pero incluso su correlación fue moderada o baja. Otras variables como el Stripping Ratio (SR), la Ley Media de Reserva (RMG) y la Vida Útil de la Mina (LOM) mostraron una influencia mínima en la variabilidad del CAPEX dentro de la muestra analizada. Estos resultados concuerdan con los estudios de Guo et al. [17], quienes demostraron que el CAPEX depende de una gran cantidad de factores operacionales y financieros, muchos de los cuales no se incluyeron en este modelo.




Figura 5.- Matriz de Pearson para evaluación de variables predictoras

Los resultados obtenidos, aunque prometedores, reflejan las limitaciones de trabajar con una base de datos reducida, como lo sugieren [17], quienes destacan que la cantidad de datos es un factor crucial para mejorar la precisión de los modelos predictivos. En este sentido, el reducido número de observaciones utilizadas en el entrenamiento del modelo pudo haber afectado su capacidad para capturar patrones más complejos en la estimación del CAPEX, limitando su capacidad de generalización y aumentando el margen de error en ciertos casos.

Estas variaciones ponen de manifiesto la influencia del tamaño de la muestra, tal como lo señalan Nourali & Osanloo [13], quienes destacan la importancia del ajuste iterativo en el desarrollo de redes neuronales artificiales. Según estos autores, el refinamiento continuo de los parámetros del modelo y la incorporación progresiva de datos adicionales pueden reducir la brecha entre valores estimados y reales, mejorando así la precisión del modelo.

Por otro lado, los resultados revelaron que los parámetros Producción Anual de Mina (P_A) y Producción Anual del Molino (P_A_M) fueron los más influyentes en el modelo predictivo del CAPEX, lo que confirma las observaciones de Guo et al. [17]. Estos hallazgos sugieren que estas variables desempeñan un papel determinante en la estimación del costo de capital minero, ya que están directamente relacionadas con la escala operativa y la eficiencia del procesamiento del mineral. Además, esto respalda la efectividad del uso de redes neuronales artificiales, las cuales han demostrado ser herramientas robustas para la modelización de fenómenos complejos en la industria minera, permitiendo capturar patrones no lineales que métodos tradicionales de regresión no logran identificar con la misma precisión.

A pesar de estas fortalezas, los resultados también sugieren que la implementación de técnicas de optimización de hiperparámetros, el uso de arquitecturas híbridas y la inclusión de variables macroeconómicas podrían mejorar aún más la capacidad predictiva del modelo, haciendo que la estimación del CAPEX sea más precisa y confiable para la toma de decisiones estratégicas en proyectos mineros a cielo abierto.

3. Analisis de Sensibilidad

Se realizó un análisis de sensibilidad para identificar las variables que más influyen las predicciones. En el modelo de predicción del precio del cobre, la variación histórica demostró ser el factor más determinante. Variables macroeconómicas adicionales mostraron baja correlación con el precio del cobre. En el modelo de CAPEX, la Producción Anual de Mina y de Molino fueron las variables de mayor impacto, mientras que el Stripping Ratio y la Ley Media de Reserva tuvieron influencia menor. Estos hallazgos son consistentes con estudios previos que destacan la importancia de factores operativos principales en costos de capital mineros.

Además, en la segunda parte del estudio, relacionada con la predicción del CAPEX, se observaron limitaciones metodológicas importantes. El modelo desarrollado presentó una baja capacidad predictiva ($R^2 < 0.01$), lo que evidencia la necesidad de mejorar tanto la estructura del modelo como la selección de variables relevantes. Asimismo, se requiere una mejora en la redacción de los resultados, la organización estructural de los mismos y una mayor profundidad en la discusión comparativa con estudios previos. Estos aspectos serán críticos para fortalecer la validez de futuras investigaciones en este campo.

4. Limitaciones

Este estudio presenta algunas limitaciones que deben ser consideradas al interpretar los resultados. La principal limitación fue la cantidad limitada de datos, especialmente en la predicción del CAPEX. Además, los modelos fueron sensibles a la presencia de valores atípicos en los conjuntos de datos. Se recomienda para futuros trabajos incrementar el tamaño de los datos, optimizar hiperparámetros y considerar modelos híbridos para mejorar la robustez de las predicciones.

IV. CONCLUSIONES

El estudio confirma que la inteligencia artificial y el Machine Learning tienen un gran potencial en la predicción del precio del cobre, permitiendo generar estimaciones más precisas basadas en patrones

históricos. Los resultados obtenidos mediante el modelo seleccionado demuestran que la variación histórica del precio del cobre es un factor clave en su pronóstico, dado que refleja la dinámica de oferta y demanda en los mercados internacionales..

Uno de los hallazgos más relevantes del estudio fue la capacidad del modelo para predecir el precio del cobre con un horizonte de 7 días en el futuro, logrando resultados satisfactorios en términos de precisión. Si bien esta capacidad predictiva representa un avance significativo para la planificación financiera y estratégica en la industria minera, se identificaron ciertas limitaciones en la estabilidad y robustez del modelo. Para mejorar la confiabilidad de las predicciones, se recomienda el uso de modelos híbridos que combinen técnicas de Machine Learning con enfoques tradicionales, así como la optimización de hiperparámetros mediante técnicas avanzadas. Esto permitiría mejorar la precisión y reducir la incertidumbre en las predicciones, facilitando una toma de decisiones más efectiva para empresas mineras e inversionistas del sector.

En cuanto al modelo de estimación del CAPEX minero, los resultados reflejan que, si bien las técnicas de Machine Learning ofrecen herramientas innovadoras para el análisis de costos de inversión, la precisión del modelo desarrollado en este estudio fue limitada. La baja capacidad explicativa del modelo (R^2 bajo) sugiere que los datos utilizados no capturan completamente la complejidad de los factores que influyen en el CAPEX. Además, se identificó que el desempeño del modelo MLP Regressor fue limitado debido a su sensibilidad a los parámetros iniciales y a la necesidad de grandes volúmenes de datos bien estructurados para alcanzar una generalización adecuada. A pesar de estas limitaciones, el estudio confirma que la inteligencia artificial y el Machine Learning tienen un gran potencial en la optimización de costos y planificación financiera en la minería, reduciendo los riesgos de inversión y permitiendo una toma de decisiones más informada en proyectos de gran escala.

REFERENCIAS

- [1] Grupo Formax. (2020). Tendencias en la inversión minera y optimización de costos. Informe técnico interno.
- [2] Santibáñez, R. (2022). Aplicaciones del Machine Learning en la predicción de precios de commodities: Un enfoque en la minería del cobre. *Revista de Ingeniería Económica*, 18(2), 45-
- [3] Santibáñez, R. (2022). Estimación del CAPEX minero utilizando modelos de inteligencia artificial. *Congreso Internacional de Economía Minera, Actas 2022*, pp. 120-135.
- [4] Gitman, L. J., & Joehnk, M. D. (2009). Fundamentos de inversiones. Pearson Educación.
- [5] Castillo Liberato, J. (2022). Impacto de los costos operativos en la inversión minera: Un análisis basado en datos históricos y proyecciones económicas. *Universidad Nacional de Ingeniería, Tesis de Maestría*..

- [6] Australian Mining. (2022). Mining investment trends and cost optimization strategies in the global industry. *Australian Mining Journal*, 32(4), 50-65.
- [7] García, M., & Pantigoso, J. (2020). Análisis de factores que afectan el CAPEX en proyectos mineros: Un estudio en América Latina. *Revista Latinoamericana de Economía Minera*, 25(1), 78-95.
- [8] Fosca Gamarra, L. (2020). Modelos predictivos en la industria minera: Aplicaciones y desafíos. *Universidad de Chile, Facultad de Ingeniería*.
- [9] Schwarz, T. (2018). Machine Learning for resource estimation in mining projects: Challenges and future trends. *Mining Technology Review*, 15(3), 112-130.
- [10] Mohutsiwa, M., & Musingwini, C. (2015). Capital cost estimation in mining projects: A machine learning approach. *Journal of Mining Economics*, 21(2), 210-225.
- [11] Estrada, C. (2022). Estrategias de optimización del CAPEX en la industria minera mediante modelos de regresión avanzada. *Revista de Finanzas Mineras*, 19(1), 33-48.
- [12] Accenture. (2018). Artificial Intelligence in Mining: Transforming Capital Investment Decisions. Informe técnico global.
- [13] Nourali, H., & Osanloo, M. (2018). A regression-tree-based model for mining capital cost estimation. *International Journal of Mining, Reclamation and Environment*, 32(4), 275-290.
- [14] Nourali, H., & Osanloo, M. (2018). Mining capital cost estimation using Support Vector Regression (SVR). Departamento de Ingeniería de Minas y Metalurgia, Universidad Tecnológica de Amirkabir, Teherán, Irán.
- [15] Hatayama, H., & Tahara, K. (2018). Adopting an objective approach to criticality assessment: Learning from the past. *Resources Policy*, 58, 46-57.
- [16] Alameer, Z., Abd Elaziz, M., Ewees, A., Ye, H., & Jianhua, Z. (2019). Forecasting Copper Prices Using Hybrid Adaptive Neuro-Fuzzy Inference System and Genetic Algorithms. *Natural Resources Research*, 28(4), 1299-1315.
- [17] Guo, H., Nguyen, H., Vu, D.-A., & Bui, X.-N. (2021). Forecasting mining capital cost for open-pit mining projects based on artificial neural network approach. *Resources Policy*, 74, 101474. ELSEVIER.