



Inteligencia Artificial como Soporte en la Toma de Decisiones Financieras en Minería

Alessandra Morante Pérez-Reyes

Resumen

Esta investigación examina el uso de Inteligencia Artificial (IA) en la industria minera para mejorar la toma de decisiones estratégicas y las inversiones. Se destaca la importancia del big data y cómo la Inteligencia Artificial, en particular el aprendizaje automático y el aprendizaje profundo, ha transformado la gestión de operaciones mineras al permitir el procesamiento de grandes volúmenes de datos y la predicción precisa de precios de commodities como el oro y el cobre. Estos algoritmos sofisticados brindan información valiosa para evaluar la viabilidad de proyectos mineros, calcular retornos de inversión y gestionar riesgos asociados con la volatilidad de los precios. Además, se explora el uso de la Inteligencia Artificial en la estimación de costos de capital en la industria minera. Los modelos basados en aprendizaje automático y redes neuronales han mejorado la precisión en la estimación de costos operativos y de capital al analizar grandes cantidades de datos históricos e identificar patrones

relevantes. Esto es esencial para una planificación y evaluación efectiva de proyectos mineros. Las plataformas de data e información utilizadas en la industria minera se pueden convertir en un aliado estratégico para la implementación de modelos innovadores. De manera complementaria, se presenta un análisis comparativo de dichas plataformas, considerando aspectos como la velocidad de respuesta, facilidad de uso, capacidad de integración, calidad de los datos y herramientas de análisis. Este análisis proporciona una guía para que los profesionales mineros seleccionen la plataforma más adecuada a sus necesidades específicas, permitiéndoles optimizar sus operaciones y tomar decisiones informadas basadas en datos confiables. Para aprovechar plenamente los algoritmos de Inteligencia Artificial en las áreas de finanzas e inversiones, es crucial fomentar una cultura organizativa que valore la innovación y la adaptabilidad, con líderes dispuestos a invertir en capacitación y tecnologías emergentes, promoviendo así una mentalidad orientada hacia el futuro.

Introducción

En la era de la transformación digital, las empresas se están beneficiando cada vez más de la inclusión de nuevas tecnologías de Inteligencia Artificial: aprendizaje automático (o “machine learning”) y aprendizaje profundo (o “deep learning”) en sus modelos de negocio. El desarrollo del aprendizaje automático ha cambiado el modo tradicional de crear conocimiento para enfocarnos en la recopilación de datos en paralelo a la aplicación de modelos de contraste y verificación (Galan Zazo, Galan Ordox, & Turrion Diez, 2022). La extensión en el uso del big data ha volcado aún más el interés en el aprendizaje automático puesto que desafía sus algoritmos a través de la provisión de un gran volumen de data que exhiben diferentes patrones de comportamiento (Zhou, Shimei, Wang, & Vasilakos, 2017). En otras palabras, el aprendizaje automático se alimenta de la diversidad de fuentes y grado de complejidad del big data para reducir el margen de error en sus modelos de predicción y aprendizaje continuo. En el caso de la industria minera, se está aprovechando en mayor medida la capacidad de recopilar y analizar grandes volúmenes de datos en tiempo real que provee los algoritmos de Inteligencia Artificial para incrementar la eficiencia operativa, y el monitoreo de los equipos y de la seguridad en los yacimientos. Sin embargo, estos algoritmos también pueden convertirse en un aliado estratégico en las áreas de inversiones y finanzas de las empresas mineras. La Figura 1 ilustra el grado de adopción de algoritmos de aprendizaje profundo y/o aprendizaje automático en la industria minera. Las áreas con una mayor integración y difusión de herramientas de Inteligencia Artificial están directamente

asociadas con las operaciones mineras, como la exploración y el desarrollo de minas. En el extremo opuesto, se encuentran las áreas de suministros, finanzas e inversiones, que muestran un nivel de implementación más bajo. Esta investigación se centra en profundizar en estas últimas áreas, buscando comprender las barreras y oportunidades para una mayor incorporación de tecnologías de Inteligencia Artificial en el ámbito minero, con el objetivo de optimizar y mejorar la toma de decisiones en estas esferas críticas de la industria.

La estimación del precio de los commodities es esencial para las áreas de finanzas e inversiones de las empresas mineras, hedgers y formuladores de políticas económicas, y como tal, ha conllevado a años de estudios con el objetivo de predecirlos con la mayor precisión posible. En los últimos veinte años los periodos de alta volatilidad en los precios commodities han retado al uso del análisis técnico y fundamental tradicional para favorecer la aplicación de modelos estocásticos, y recientemente, la utilización de modelos soportados por Inteligencia Artificial (Hachmi, Boubaker, Ftiti, Louhichi, & Tissaoui, 2023). Por otro lado, la investigación realizada por Zhang, Hong y otros proponen el uso de una combinación de red neuronal profunda (DNN) y optimización por colonia de hormigas (ACO) para estimar los costos de capital y de capital de trabajo de proyectos mineros. Los costos de capital son una pieza fundamental para el planeamiento de minado y el cálculo del Valor Presente Neto (NPV), el cual determina el atractivo de los proyectos durante las valorizaciones (Zhang, y otros, 2020). Asimismo, de manera genérica, la industria minera se

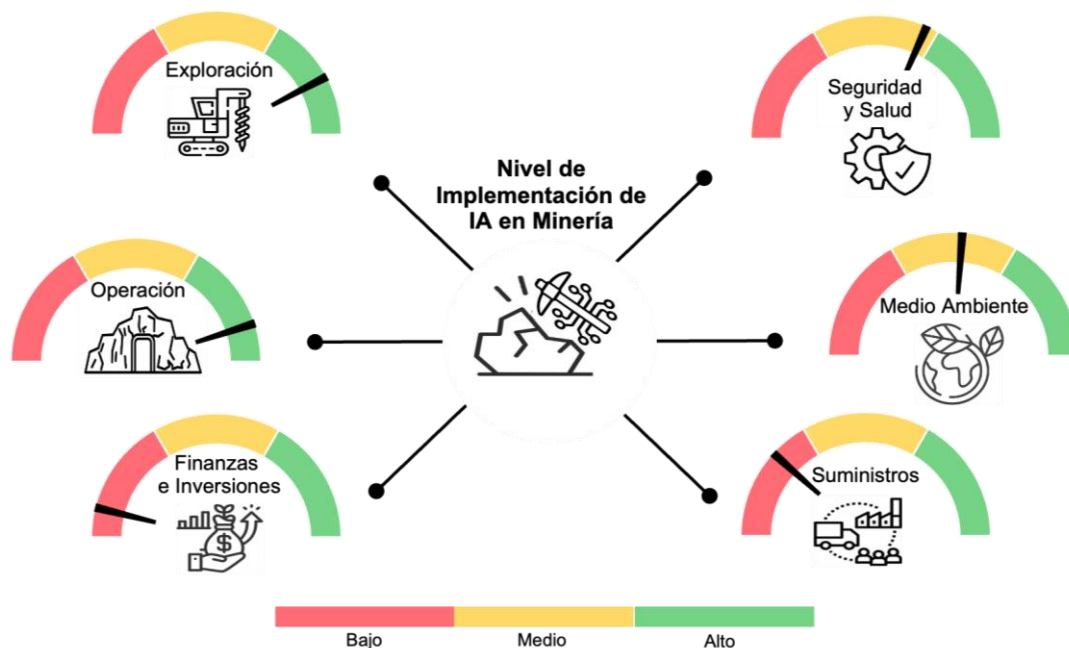
puede beneficiar de las innovaciones tecnológicas en la gestión de riesgos financieros, y los consultores, en el otorgamiento de recomendaciones sobre carteras de riesgo a inversionistas individuales digitalmente y con poca intervención humana (Méndez-Suárez, García-Fernández, & Gallardo, 2019).

El objetivo de esta investigación es proporcionar al lector una comprensión general de los conceptos de big data y los algoritmos de Inteligencia Artificial disponibles. Además, busca ampliar la perspectiva del uso de estos algoritmos en las operaciones mineras, abarcando también las áreas de desarrollo empresarial e inversiones. También se realiza una comparación de las plataformas de datos y análisis, muchas de las cuales son respaldadas por Inteligencia Artificial, en términos de calidad y diversidad de los datos, así como la

eficiencia de la plataforma. Estas plataformas pueden ser un aliado estratégico para la creación de modelos de aprendizaje profundo ad hoc y mejorar el proceso de toma de decisiones estratégicas en el negocio minero.

Figura 1:

Implementación y Uso de la Inteligencia Artificial en la Industria Minera



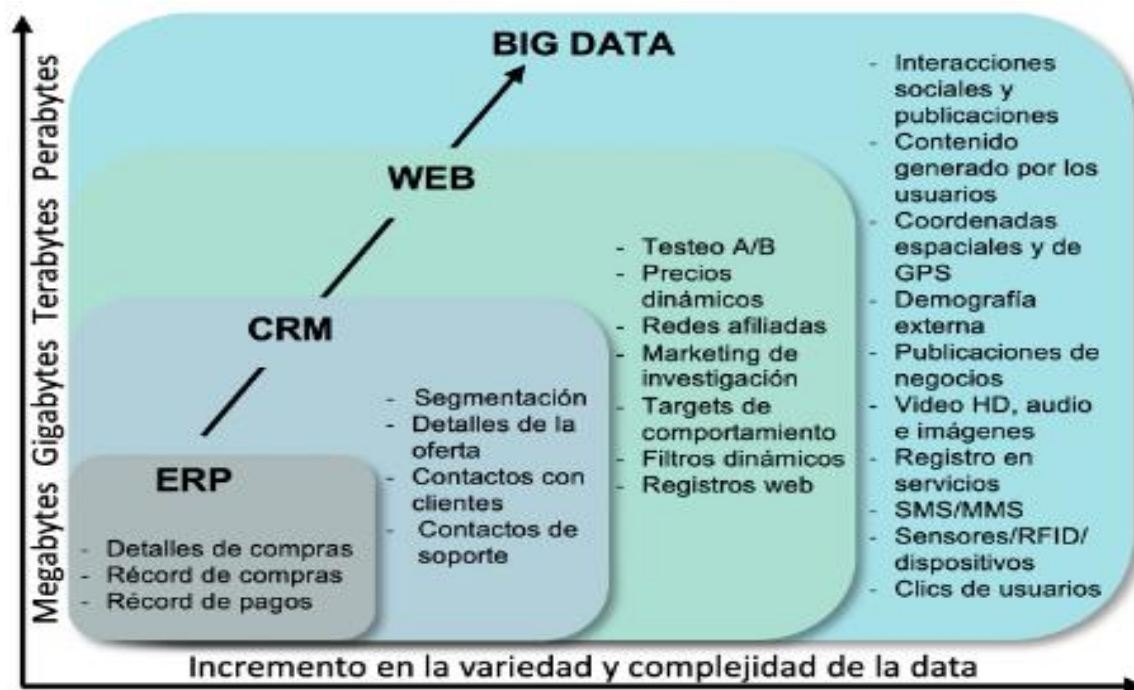
Nota. La Figura 1 muestra el nivel de adaptación e inclusión de algoritmos de Inteligencia Artificial en la Industria Minera por área.

Conectando el Big Data, la Ciencia de Datos y la Inteligencia Artificial

Antes de abordar las herramientas de Inteligencia Artificial utilizadas como apoyo para las inversiones mineras y la toma de decisiones estratégicas, es fundamental dar un paso previo importante al adentrarnos en el conocimiento de las fuentes de datos, especialmente aquellas respaldadas en línea, como el big data. En la figura 2 se revela la evolución del acceso a estos datos, llevándonos al concepto de big data, tomando como ejemplo el manejo de datos de clientes. Uno de los cambios más trascendentales ocurrió durante la tercera revolución tecnológica, en la segunda mitad del siglo XX, con la creación de las Tecnologías de la Información y Comunicaciones (TIC) que marcaron el inicio del análisis computarizado basado en el uso de plataformas de inteligencia de negocios, big data y ciencia de datos (Golebiowska & Prokopowicz, 2021). A partir de 2005, las empresas comenzaron a prestar atención a los datos generados por los usuarios a través de servicios en línea. Es necesario recolectar, procesar y analizar todo tipo de datos: estructurados y no estructurados. En pocas palabras, el término big data se refiere a un conjunto de datos complejos provenientes de diversas fuentes que resulta demasiado extenso para ser procesado por herramientas de análisis tradicionales (Oracle, 2022). Para manejar esta data potencialmente invaluable, se desarrollan nuevas metodologías de ciencia de datos y nuevas aplicaciones en la forma de análisis predictivo (Waller & Fawcett, 2013). El big data se caracteriza por tres aspectos clave: variedad, volumen y velocidad (Oracle, 2022).

Figura 2

Evolución de la Información y el Big Data



Nota. La Figura 2 ilustra el proceso de desarrollo de las tecnologías de la información que condujeron al surgimiento del concepto de Big Data. Tomando de *Business Intelligence analytics based on the processing of large sets of information with the use of sentiment analysis and Big Data* por Golebiowska & Prokopowicz, 2021.

Por otro lado, la ciencia de datos se basa en la aplicación de métodos cuantitativos y cualitativos para resolver problemas significativos y predecir resultados (Waller & Fawcett, 2013). Los científicos de datos emplean una variedad de técnicas, como el modelado estadístico, el aprendizaje automático y la minería de datos, con el objetivo de identificar patrones y tomar decisiones basadas en datos. Un aspecto fundamental destacado por Waller y Fawcett es que el conocimiento del dominio y el análisis de datos son inseparables, lo que implica que los científicos de datos necesitan tanto un profundo conocimiento del dominio como habilidades analíticas (Waller & Fawcett, 2013).

En párrafos anteriores, se han explicado de manera general los conceptos de big data y ciencia de datos, así como sus ventajas en la recopilación, análisis y aprovechamiento de grandes volúmenes de datos, y cómo estas disciplinas están interrelacionadas. Ahora bien, tanto el big data como la ciencia de datos han sentado las bases para el avance de la Inteligencia Artificial, la cual tiene la capacidad de imitar y simular la inteligencia humana para realizar tareas de forma autónoma. Un número cada vez mayor de empresas, aproximadamente el 35% a nivel global, están utilizando Inteligencia Artificial en sus procesos, mientras que otro 42%, está explorando esta tecnología (IBM Data and AI Team, 2023). La Inteligencia Artificial, como disciplina de las ciencias de la computación, ha revolucionado la gestión de las operaciones mineras al permitirnos procesar grandes volúmenes de datos, identificar patrones complejos y realizar predicciones más precisas y confiables. Específicamente, los mercados de commodities se enfrentan a una complejidad derivada de la interacción entre diversos factores, como eventos políticos, oferta y demanda, mercados financieros y tasas de cambio. Esta interacción genera una mayor complejidad en las series de datos, caracterizadas por su asimetría, dinámica no lineal, patrones caóticos, falta de estacionalidad y heterogeneidad (Hachmi, Boubaker, Ftiti, Louhichi, & Tissaoui, 2023), lo cual requiere algoritmos más sofisticados como el aprendizaje automático o el aprendizaje profundo.

El aprendizaje automático es una rama de la Inteligencia Artificial que utiliza datos y algoritmos para imitar la forma en que los humanos aprenden. Se entrenan algoritmos mediante el uso de métodos estadísticos para realizar clasificaciones, predicciones y descubrir información clave en proyectos de minería de datos (UC Berkeley School of Information, 2020). Hoy en día, los algoritmos de aprendizaje automático son técnicamente de fácil acceso, ya que se pueden descargar paquetes convenientes en R o Python que permiten ajustar árboles de decisión, bosques aleatorios o coeficientes de regresión LASSO (Mullainathan & Spiess, 2017).

El método fundamental del aprendizaje automático aplicado a un algoritmo supervisado se basa en el siguiente proceso (UC Berkeley School of Information, 2020):

- Proceso de decisión: El algoritmo identifica patrones en los datos ingresados.
- Función de error: Se utiliza una función para medir la precisión del modelo mediante la comparación con datos de control conocidos.
- Optimización del modelo: El objetivo de esta etapa es mejorar la capacidad predictiva del algoritmo mediante el ajuste de ponderaciones. La funcionalidad del algoritmo dependerá del rango máximo de tolerancia a las desviaciones de precisión.

La elección del algoritmo de aprendizaje automático más adecuado dependerá del problema a resolver y el número de variables involucradas. El aprendizaje será supervisado cuando se

identifica una función que vincula la data de entrada con la data de salida basada en un ejemplo de pares de entrada y salida conocidos. Los algoritmos más comunes de data supervisada son el árbol de decisión, el teorema de bayes y la máquina de soporte de vectores (SVM). Por otra parte, en el aprendizaje no supervisado, los algoritmos tienen que descubrir por sí mismo una estructura para los datos. Cuando se introduce nueva información, se utilizan las características aprendidas previamente para clasificar los datos (Mahesh, 2018). El algoritmo más común es la agrupación en clústeres.

En los últimos tiempos, ha surgido la necesidad de algoritmos más complejos de aprendizaje automático, lo cual ha llevado al desarrollo del campo del aprendizaje profundo. La diferencia principal entre el aprendizaje automático y el aprendizaje profundo es cómo cada algoritmo aprende y cuántos datos utiliza cada tipo de algoritmo (IBM Data and AI Team, 2023). El aprendizaje profundo es un enfoque especial de las redes neuronales artificiales que utiliza múltiples capas para extraer las características más relevantes de datos previos. Se ha utilizado con éxito en diversos campos, como el procesamiento de imágenes y la predicción de series de tiempo en escenarios cambiantes. A diferencia de las redes neuronales tradicionales, el aprendizaje profundo tiene la capacidad de utilizar información del pasado y procesar datos en ambas direcciones. Esta característica lo hace más eficaz en tareas de predicción y análisis de datos. Cada uno de estos tipos de algoritmos, aprendizaje automático y aprendizaje profundo, se aplica de manera específica a cada caso (Hachmi, Boubaker, Ftiti, Louhichi, & Tissaoui, 2023).

Tabla 1*Comparación entre Aprendizaje Automático y Aprendizaje Profundo*

| Aspecto | Aprendizaje Automático | Aprendizaje Profundo |
|------------------------------------|---|--|
| Enfoque en decisiones estratégicas | Proporciona predicciones precisas y rápidas | Permite análisis complejos y detallados |
| Cantidad de datos requeridos | Requiere datos moderados para entrenar | Necesita grandes conjuntos de datos para un rendimiento óptimo |
| Interpretabilidad | Ofrece una mayor interpretación de resultados | Los resultados pueden ser menos interpretables |
| Tareas de aplicación | Análisis de riesgo, estimación de precios | Pronóstico de tendencias a largo plazo, recomendaciones de inversión |
| Flexibilidad | Menos flexible en tareas complejas y cambiantes | Mayor flexibilidad y adaptabilidad en tareas desafiantes |
| Requisitos computacionales | Menos recursos computacionales requeridos | Puede necesitar recursos computacionales más potentes |

Nota. La Tabla 1 compara el Aprendizaje Automático y el Aprendizaje Profundo desde la perspectiva de los usuarios

Uso de Inteligencia Artificial para la Estimación de Precios de los Commodities

La Estimación de Precios como Motor de Políticas Económicas y Decisiones Estratégicas

En el dinámico mundo de los mercados de commodities, la estimación precisa de los precios desempeña un papel trascendental que desafía tanto a la economía como a las estrategias empresariales. Desde la formulación de políticas económicas hasta la toma de decisiones estratégicas por parte de las áreas de finanzas e inversiones de las empresas mineras, la capacidad de anticipar y comprender la fluctuación de los precios, debido a factores como la oferta y la demanda, conflictos geopolíticos y cambios en las políticas gubernamentales, es un elemento crucial para evaluar la viabilidad de proyectos, determinar los márgenes de ganancia y gestionar los riesgos asociados con la volatilidad de los precios.

Los gobiernos ejercen una influencia importante en el precio de los commodities a través de la introducción de políticas y regulaciones de mercado, especialmente durante períodos de

aumento de precios (Tapia Cortez, Saydam, Coulton, & Sammut, 2018). Por lo tanto, contar con la capacidad de prever con certeza los precios les permitirá establecer políticas sólidas y adecuadas para mantener la estabilidad financiera del país.

Además, las empresas mineras comprometen una importante suma de capital y asumen un riesgo alto. Los retornos sobre la inversión están por debajo de estos valores para otras industrias por largo periodos y están sujetos a movimientos impredecibles en los precios de los commodities (Samis &

Steen, 2020). La estimación de los precios permite calcular los ingresos por la venta de los minerales, pero fundamentalmente, determinar el plan óptimo de extracción del mineral, lo que crea la base para el proceso de planeamiento y presupuesto (Szarek, Bielak , & Wyłomańska, 2020).

Por otro lado, los mercados de futuros ofrecen herramientas de cobertura que permiten proteger la posición de efectivo de las empresas al eliminar la incertidumbre causada por cambios inesperados en los precios de los commodities. El precio spot es el valor actual de mercado al cual el commodity se compra o vende con pago y entrega inmediata. Los precios spot se determinan dos veces al día en función de la oferta y demanda del mercado global del commodity. Esto difiere de los precios futuros, donde dos partes acuerdan intercambiar a un precio en una fecha futura (Ghosh, Tamal Datta, Alfaro-Cortes, Gamez, & Garcia, 2022). Comprender los determinantes de la oferta y la demanda, así como sus interacciones, y el efecto del comportamiento humano, permitirá identificar oportunidades y establecer precios razonables en las negociaciones de cobertura.

En este contexto, la tecnología y los modelos predictivos desempeñan un rol cada vez más importante. La Figura 3 muestra las categorías de datos cuantitativos y cualitativos utilizados frecuentemente en la estimación de precios de commodities. Entre los datos cualitativos más importantes, están los cambios en la política y regulación, el impacto de los eventos geopolíticos, las noticias y eventos del mercado, los cambios en los hábitos de consumo y el sentimiento del mercado¹. Por otro lado, los datos cuantitativos incluyen a la oferta y demanda del mercado, a los cambios en los precios de suministros, los precios históricos del mismo commodity, los factores económicos cuantificables, como la tasa de interés y el tipo de cambio, y el impacto de las nuevas tecnologías. Mediante el análisis de grandes cantidades de datos históricos y, el uso de algoritmos avanzados y el aprendizaje automático, se han desarrollado herramientas que ayudan a anticipar las tendencias de precios y a tomar decisiones fundamentadas. Estas herramientas proporcionan a los actores del mercado una ventaja competitiva al proporcionar información valiosa y permitir una planificación estratégica más sólida.

¹ El sentimiento del mercado refleja las actitudes y emociones de los inversores hacia los mercados financieros, influyendo en sus decisiones de inversión. Se mide mediante indicadores como el índice de volatilidad VIX y análisis de redes sociales (Palacios, 2023).

Figura 3

Diversidad de Datos Estructurados y No Estructurados Necesarios para la Estimación de Precios de Commodities



Nota. La Figura 3 muestra los datos utilizados en la estimación de precios de commodities divididos en datos cuantitativos y cualitativos, destacando sus diferencias entre datos medibles y descriptivos o intangibles.

Metodologías alternativas para estimar los precios de los commodities

En los últimos años la literatura sobre la estimación y predicción de los precios de los commodities ha evolucionado significativamente. Se ha pasado de predecir precios basándose en factores macroeconómicos, incertidumbre económica y factores financieros, como los movimientos en los mercados de capital, a la incorporación del uso de herramientas de investigación operativa, como aquellas basadas en la Inteligencia Artificial. La elección entre algoritmos de aprendizaje automático y de aprendizaje profundo dependerá de la complejidad de la estimación, por lo tanto, se evaluará caso por caso (Hachmi, Boubaker, Ftiti, Louhichi, & Tissaoui, 2023). Es importante considerar que las metodologías no son excluyentes y pueden combinarse para obtener mejores estimaciones. Además, el avance tecnológico está impulsando el desarrollo de nuevas herramientas y enfoques para la estimación de precios en la industria minera.

Antes de abordar el tema específico de las innovaciones recientes en los modelos de estimación de precios de commodities, es importante tener una comprensión de la evolución de los enfoques y metodologías utilizados hasta ahora. A continuación, se proporciona un resumen de dicha evolución:

- **Métodos Tradicionales:** Hasta mediados del siglo XX, la estimación de los precios de los commodities se basaba exclusivamente en el análisis de datos históricos, considerando el impacto de factores macroeconómicos, incertidumbre económica y elementos financieros como los movimientos en los mercados de capital (Hachmi, Boubaker, Ftiti, Louhichi, & Tissaoui, 2023), en combinación con los determinantes de oferta y demanda.

Sin embargo, la data histórica no garantiza una predicción precisa puesto que no hay certeza que los eventos del pasado se van a repetir en el futuro en los mismos intervalos y con la misma intensidad (Tapia Cortez, Saydam, Coulton, & Sammut, 2018).

- Modelos Econométricos: A partir de la década de 1950, se comenzaron a utilizar modelos econométricos para estimar los precios de los commodities, basados en el análisis de la correlación entre la oferta, la demanda histórica y los precios, empleando herramientas estadísticas y matemáticas (Tapia Cortez, Saydam, Coulton, & Sammut, 2018). Este enfoque de análisis de series de tiempo representó un cambio significativo en comparación con los métodos tradicionales que se basaban únicamente en el comportamiento pasado de las variables modeladas. Los modelos más sofisticados de extrapolación surgieron como resultado de esta transición (Kennedy, 2008). Dentro de estas técnicas, el modelo vectorial autorregresivo (VAR)² y el modelo de vector de corrección de error (VEC)³ se destacan por su capacidad para examinar información pasada, comprender el comportamiento de las variables y detectar fluctuaciones. Algunos estudios más recientes han retado la confiabilidad de estas predicciones a favor de los modelos estocásticos caracterizados por la aplicación de restricciones preestablecidas a las estimaciones de precios. Estos modelos permiten medir y entender la escala, y probabilidad de los potenciales movimientos en los precios (Szarek, Bielak, & Wyłomańska, 2020), aceptando que existen múltiples variables que pueden afectar en diversos momentos el comportamiento de los precios de los commodities.
- Modelos de Oferta y Demanda: A partir de la década de 1990, se empezaron a desarrollar modelos más sofisticados que consideraban detalladamente la oferta y la demanda de commodities, así como factores económicos, políticos y sociales que influyen en los precios. La demanda de commodities está influenciada por diversos factores, tales como el precio en sí, la existencia de productos sustitutos y complementarios, los cambios tecnológicos y las preferencias de los consumidores. Por otro lado, los principales factores que afectan la oferta de minerales incluyen el precio mismo del commodity, los costos laborales y de otros insumos, las innovaciones tecnológicas que impactan en la eficiencia operativa y las interrupciones en la producción (Tilton & Guzman, 2016).

Modelos Basados en Inteligencia Artificial

El aprendizaje automático y el aprendizaje profundo han transformado la manera en que se llevan a cabo predicciones y análisis en diversas industrias, incluyendo la minería. En particular, se han realizado numerosas investigaciones que proponen el uso de redes neuronales para la estimación de precios de commodities como el oro y el cobre. Estas poderosas herramientas de aprendizaje automático y aprendizaje profundo han generado nuevas oportunidades en la industria minera al proporcionar una comprensión más profunda

² El modelo vectorial autorregresivo (VAR) es una versión simplificada de los modelos multivariados que usan los valores históricos de todas las variables del sistema para describir el comportamiento de cada variable. (Tapia Cortez, Saydam, Coulton, & Sammut, 2018)

³ El modelo de vector de corrección de error (VEC) es una versión especial del VAR para variables estacionales. (Tapia Cortez, Saydam, Coulton, & Sammut, 2018)

de los mercados y facilitar la toma de decisiones fundamentadas. Mediante la aplicación de algoritmos sofisticados y el análisis de grandes volúmenes de datos, las empresas mineras pueden mejorar su capacidad para prever los cambios en los precios y adaptar sus estrategias en consecuencia, lo que les brinda una ventaja competitiva significativa en un entorno económico dinámico.

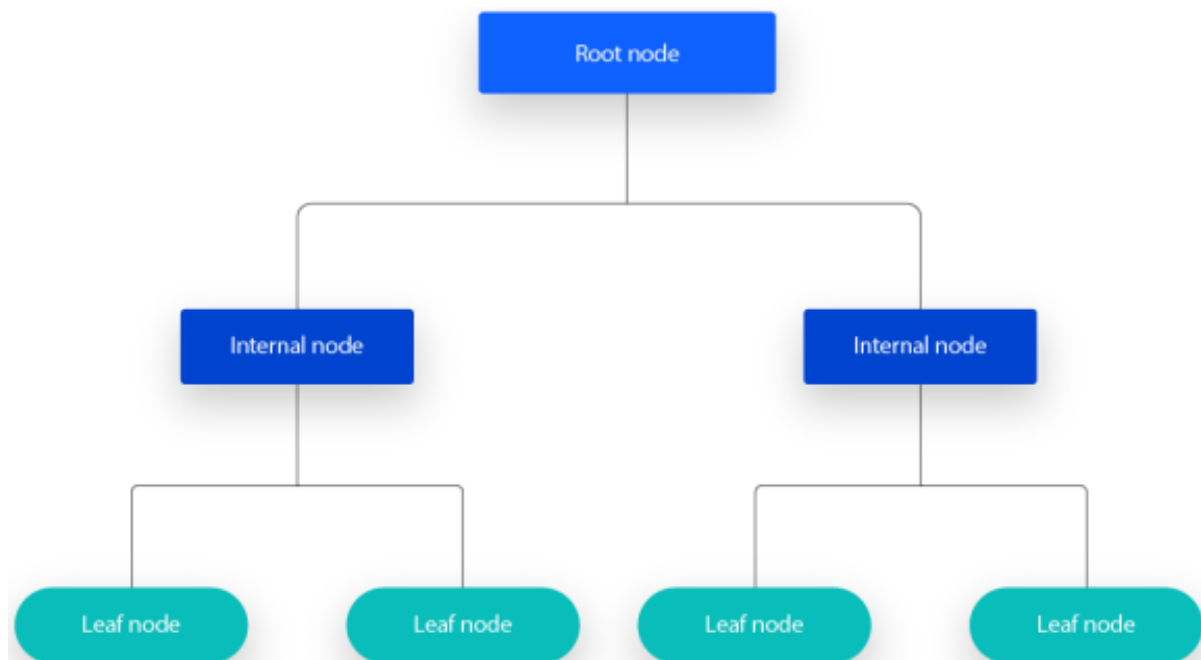
Aprendizaje Automático

Árbol de Decisión

El árbol de decisión es una herramienta de análisis gráfico que representa las opciones y los resultados en forma de un árbol. Los nodos en el árbol representan eventos u opciones, mientras que los bordes representan reglas de decisión o condiciones. En palabras simples, cada nodo es un atributo de un grupo que se clasifica y cada rama representa el valor que debe tomar cada nodo (Mahesh, 2018). Un árbol de decisión funciona dividiendo repetidamente el grupo de datos para entrenar el modelo, y luego se utiliza para predecir los valores de las salidas basándose en varias variables independientes (Liu, Hu, Li, & Shaojun, 2017). El estudio realizado por Liu y otros, concluyeron que el aprendizaje a través del árbol de decisión puede predecir con certeza los precios futuros del cobre, con un margen de error inferior al 5%. Esta precisión se mantiene en diferentes escalas de tiempo, como días, meses y semanas.

Figura 4

Representación Gráfica del Árbol de Decisión




Nota. La Figura 4 representa esquemáticamente un árbol de decisión, que segmenta datos en grupos según atributos específicos para mejorar la clasificación y predicción

Redes Neuronales Artificiales (ANN)

Las ANN pueden aplicarse tanto en el aprendizaje supervisado como en el no supervisado. Son algoritmos que imitan el funcionamiento del cerebro humano para descubrir relaciones ocultas en conjuntos de datos. Las ANN tienen la capacidad de adaptarse a diferentes situaciones, lo que les permite encontrar la mejor solución sin cambiar las reglas establecidas (Mahesh, 2018). Además de las capas de entrada y salida, las redes neuronales están compuestas por una o más capas ocultas que aprenden límites de decisión no lineales para separar diferentes clases de datos (Sami & Nazir, 2018). Varios estudios han propuesto el uso de estas redes neuronales en la estimación de precios de commodities, como el oro (Sami & Nazir, 2018) y el cobre (Zhang, Nguyen, Vu, Bui & Pradhan, 2021).

Figura 5

Representación Gráfica de las Redes Neuronales Artificiales



Nota. La Figura 5 representa esquemáticamente una red neuronal artificial, estructurada en capas de nodos interconectados que simulan el proceso de aprendizaje del cerebro.

Sami y Nazir incorporaron indicadores de desempeño de los principales productores y compradores de oro del mundo, como Rusia, China, India y Estados Unidos, a los modelos de predicción de precios del oro basados en aprendizaje automático. Estos modelos tradicionalmente se enfocan únicamente en variables macroeconómicas e industriales. Los investigadores consideraron que las fluctuaciones en los precios del oro están constantemente influenciadas por las condiciones económicas de estos países. Para su análisis, utilizaron datos históricos de la cotización diaria del oro, dividiendo los datos en un 25% para pruebas y un 75% para entrenamiento. Según sus hallazgos, la eficiencia del algoritmo de la red neuronal varía según el número de capas y el tamaño del conjunto de datos de entrenamiento. Cada modelo se compone de una capa de entrada, una o más capas ocultas y una capa de salida. Estas capas ocultas procesan la información antes de enviarla a la capa de salida. Mediante un análisis de 25 variables en tres capas neuronales, lograron predecir con precisión y consistencia el precio del oro (Sami & Nazir, 2018).

Zhang, Nguyen y otros siguieron una estrategia similar a la de Sami y Nazir al incorporar en su modelo de ANN el impacto de factores macroeconómicos, como el tipo de cambio de los principales actores en la industria del cobre, como China, Estados Unidos, Perú y Australia. Para este modelo, utilizaron el 20% de los datos para probar el algoritmo y el 80% de los datos recopilados para entrenar el modelo. Los resultados del modelo indicaron que el cambio de moneda a dólares estadounidenses de los principales productores de cobre a nivel mundial tiene un efecto significativo en la volatilidad de los precios, y es esencial considerar estos factores para predecir los precios futuros. La red neuronal demostró ser el algoritmo más preciso para realizar estas predicciones (Zhang, Nguyen, Vu, Bui, & Pradhan, 2021).

Aprendizaje Profundo

Hachmi y otros investigaron el uso de herramientas de aprendizaje profundo para predecir los precios de los commodities. Para ello, aplicaron cuatro modelos de aprendizaje profundo en sus estimaciones: redes neuronales recurrentes (RNN), unidades recurrentes cerradas (GRU), memorias de corto plazo de longitud variable (LSTM) y redes neuronales convolucionales (CNN) (Hachmi, Boubaker, Ftiti, Louhichi, & Tissaoui, 2023). Las redes neuronales convolucionales son un tipo de algoritmo de aprendizaje profundo que aprende directamente de los datos de entrada sin necesidad de intervención humana, lo que las convierte en una herramienta más poderosa que los modelos tradicionales. Por otro lado, las redes neuronales recurrentes se diferencian de las redes neuronales tradicionales en que tienen la capacidad de mantener y utilizar información procesada anteriormente para la secuencia actual. Por último, el modelo de memoria de corto plazo de longitud variable es una variante de las redes neuronales recurrentes que aborda el problema del desvanecimiento de la información relevante. Este modelo permite almacenar información durante períodos prolongados y controlar el flujo de información de manera más efectiva (Sarker1, 2021). Para la validación del modelo, se utilizaron datos diarios de precios desde enero de 2002 hasta diciembre de 2020 de los siguientes índices: el Índice de Commodities de Bloomberg y sus cinco componentes: el Subíndice de Agricultura de Bloomberg, el Subíndice de Metales Preciosos de Bloomberg, el Subíndice de Ganadería de Bloomberg, el Subíndice de Metales Industriales de Bloomberg y el Subíndice de Energía de Bloomberg. En este modelo, se destinó el 10% de los datos para probar el algoritmo y el 90% de los datos recopilados para entrenar el modelo. Los resultados de los estudios concluyeron que el método que proporciona los resultados más precisos es el de LSTM (Hachmi, Boubaker, Ftiti, Louhichi, & Tissaoui, 2023).

Tabla 2

Comparación entre el Desarrollo de Modelos de Estimación de Precios con Inteligencia Artificial y los Métodos Convencionales

| Aspecto | Inteligencia Artificial | Métodos Convencionales |
|------------------------|---|--|
| Recopilación de Datos | Utiliza automatización para recoger un amplio rango de datos en tiempo real, incluyendo fuentes no estructuradas. | Dependencia de recopilación manual y análisis de datos históricos y reportes financieros. |
| Análisis Preliminar | Aplica algoritmos para un análisis preliminar, identificando patrones y tendencias relevantes automáticamente. | Análisis manual para identificar tendencias históricas y factores potencialmente influyentes. |
| Modelado y Predicción | Emplea modelos de aprendizaje automático y profundo para predecir precios futuros con base en patrones complejos. | Utiliza modelos estadísticos y económicos basados en relaciones lineales y tendencias pasadas. |
| Optimización y Ajustes | Permite ajustes en tiempo real basados en nuevos datos y resultados de predicción. | Requiere revisión manual y ajustes basados en nuevos análisis o cambios de mercado. |

Nota. La Tabla 2 compara los métodos convencionales de predicción de precios de commodities con aquellos basados en algoritmos de Inteligencia Artificial

Estimación de Costos de Capital con Inteligencia Artificial

La industria minera se enfrenta al desafío de estimar y gestionar eficientemente los costos operativos y de capital para sus proyectos. Los costos de capital comprenden los gastos de inversión relacionados con la adquisición de propiedades, derechos mineros, maquinaria y construcción de la mina, así como otros gastos de infraestructura asociados. Estos costos se realizan generalmente al inicio del proyecto y se ajustan a lo largo de la vida útil de la mina, incluyendo el mantenimiento y reemplazo de equipos (Nourali & Osanloo, 2019). La precisión en estas estimaciones es crucial para evaluar la viabilidad de los proyectos, calcular el retorno de la inversión y tomar decisiones estratégicas fundamentadas.

En la evolución de las metodologías para estimar los costos de capital, las empresas mineras solían basarse en estimaciones manuales por componentes, como la adquisición de propiedades y la construcción de la infraestructura, aplicando factores de ajuste para considerar el comportamiento del mercado. Posteriormente, se adoptaron modelos estadísticos y matemáticos más sofisticados, así como análisis de riesgo, para tener en cuenta la variabilidad y la incertidumbre en los costos de capital. Entre estos modelos destacan los Flujos de Caja Descontados (DCF), modelos estocásticos y opciones reales, que brindan mayor flexibilidad ante la incertidumbre de los eventos futuros.

En la actualidad, la Inteligencia Artificial ha transformado la estimación de costos de capital en la industria minera. Las empresas utilizan algoritmos de aprendizaje automático y redes neuronales para analizar grandes volúmenes de datos históricos, identificar patrones complejos y generar predicciones más precisas.

Numerosos estudios han explorado el potencial de la Inteligencia Artificial para mejorar la precisión en la estimación de los costos mineros. Por ejemplo, Zhang y otros proponen el uso de aprendizaje profundo para estimar los costos de capital de proyectos mineros de cobre a tajo abierto. Utilizando una combinación de redes neuronales profundas (DNN) y un algoritmo de optimización de colonia de hormigas (ACO) denominado ACO-DNN, desarrollaron modelos para pronosticar los costos de capital de proyectos mineros. (Zhang, y otros, 2020).

Los resultados del estudio indicaron que la producción anual de la mina y del molino, los ratios promedio de desbroce y la vida útil de la mina son parámetros críticos para lograr una mayor precisión en el modelo híbrido de predicción de costos de capital en proyectos de cobre. Además, los avances en la tecnología minera tienen un impacto significativo en los costos de capital de proyectos mineros a tajo abierto. Esto implica que muchas empresas mineras se enfrentan a diversos riesgos financieros debido a la incertidumbre en la estimación de los costos de capital en este tipo de proyectos. En consecuencia, resulta beneficioso tanto para las empresas mineras como para los economistas mejorar la precisión en la estimación de los costos de capital, ya que esto contribuirá a una evaluación y pronóstico más preciso del Valor Presente Neto (VPN) de las minas (Zhang, y otros, 2020).

Análisis de Mercado: Comparación de Plataformas de Data e Información

La industria minera se ha beneficiado ampliamente de las tecnologías avanzadas y la implementación de plataformas de data y análisis se ha vuelto común para mejorar la eficiencia y la toma de decisiones informadas. En esta sección, realizaremos un análisis comparativo de las principales plataformas de data y análisis utilizadas en la industria minera, centrándonos en aquellas que hacen uso de la Inteligencia Artificial. El análisis se llevará a cabo mediante la construcción de un cuadro de calor que evaluará las herramientas y la eficiencia de cada plataforma, proporcionando una visión clara de sus fortalezas y debilidades. Además, se realizará otro cuadro de calor para comparar el tipo de datos disponibles en cada plataforma, lo cual es esencial para abordar los desafíos específicos de la industria minera. A través de este análisis comparativo, ofreceremos una guía valiosa para que las empresas mineras seleccionen la plataforma más adecuada para sus necesidades de data y análisis, considerando la presencia de Inteligencia Artificial y la variedad de datos disponibles.

Metodología

En esta sección, presentamos la metodología utilizada para llevar a cabo un análisis comparativo exhaustivo de las plataformas de data y análisis en la industria minera. El objetivo es proporcionar una guía completa y confiable para las empresas mineras al seleccionar la plataforma más adecuada para sus necesidades de data y análisis.

El proceso de evaluación se basó en una cuidadosa selección de parámetros relevantes que permiten una evaluación integral de cada plataforma. Se tuvo en cuenta factores como la funcionalidad, la escalabilidad, la facilidad de uso, la capacidad de integración, la capacidad de análisis avanzado y, por supuesto, la presencia de Inteligencia Artificial. Además, se estableció una escala de calificación apropiada para garantizar una comparación justa y consistente entre las plataformas. Posteriormente, se realizó una investigación exhaustiva y un análisis detallado de cada plataforma seleccionada. Se examinaron aspectos como la calidad y la diversidad de las características ofrecidas, la capacidad de gestionar grandes volúmenes de datos, la capacidad de generar informes y visualizaciones impactantes, y la disponibilidad de herramientas avanzadas de análisis y modelado. Se evaluó también la flexibilidad y adaptabilidad de las plataformas para abordar los desafíos específicos de la industria minera. Finalmente, toda esta información se utilizó para crear cuadros de calor comparativos, que proporcionan una visualización clara y concisa de las fortalezas y debilidades de cada plataforma evaluada. Estos cuadros permiten a las empresas mineras tomar decisiones informadas y estratégicas al seleccionar la plataforma más adecuada para optimizar sus operaciones y tomar decisiones basadas en datos confiables. Un enfoque riguroso y detallado asegura que las empresas mineras puedan aprovechar al máximo las ventajas de la tecnología de data y análisis en su búsqueda de la excelencia operativa y la toma de decisiones informadas.

Elección de Parámetros

La evaluación del desempeño de las plataformas de datos se divide en dos secciones trascendentales. En primer lugar, se encuentran los indicadores de eficiencia, que miden la funcionalidad general de la tecnología. Estos parámetros son aplicables a todas las plataformas y tecnologías de datos, brindando una base sólida para la comparación. Por otro lado, se encuentran los indicadores que evalúan la amplitud, nivel de detalle y análisis que proveen a los usuarios. En este caso, se toman en consideración las necesidades específicas de los usuarios, ya que se evalúa la capacidad de la plataforma para proporcionar la data y análisis que satisfagan dichas necesidades. Se considerarán variables que respalden la toma de decisiones estratégicas de las áreas de finanzas e inversión de las empresas mineras y de los gobiernos.

Mediante esta evaluación exhaustiva, se busca brindar una visión integral que permita a los usuarios seleccionar la plataforma que mejor se ajuste a sus requerimientos. El objetivo es proporcionar información objetiva y rigurosa que respalde la toma de decisiones informadas, basadas en las necesidades específicas de cada usuario y en la capacidad de las plataformas para ofrecer data y análisis de alta calidad. Al seleccionar la plataforma adecuada, los usuarios podrán impulsar la eficiencia de sus operaciones y mejorar su capacidad para tomar decisiones.

Parámetros de Eficiencia

A continuación, se presentarán de manera concisa los parámetros seleccionados para evaluar la eficiencia y funcionalidad de las plataformas de servicio. Los parámetros seleccionados abarcan aspectos clave, como la accesibilidad de la plataforma, la calidad de la data y el análisis proporcionado, la capacidad de generación de informes, la velocidad y eficiencia en el procesamiento de datos, la seguridad y la capacidad de integración con otras herramientas y sistemas.

- Velocidad de Respuesta: Este criterio se centra en la rapidez con la que la plataforma responde a las consultas y solicitudes de los usuarios. Esto abarca tanto la velocidad de generación de búsquedas y reportes personalizados en la plataforma, como la eficiencia del soporte proporcionado por las empresas de tecnología asociadas. La capacidad de respuesta rápida permitirá a los financistas y/o inversionistas del sector minero obtener datos en tiempo real sobre los precios de los metales o cambios en las regulaciones y condiciones del mercado, lo que les permitirá ajustar sus estrategias y tomar decisiones informadas de manera oportuna.
- Facilidad de Uso: Este criterio evalúa la interfaz de la plataforma, considerando su nivel de amigabilidad e intuitividad para el usuario. Una interfaz amigable facilita el flujo de trabajo, aumenta la productividad y garantiza que los usuarios puedan aprovechar al máximo las capacidades de la tecnología para obtener resultados sólidos y tomar decisiones acertadas. Una interfaz intuitiva permite una navegación sencilla y una comprensión clara de las funciones y herramientas

disponibles. Esto reduce la curva de aprendizaje y permite a los usuarios utilizar la plataforma de manera efectiva desde el principio.

- Capacidad de Integración: El siguiente parámetro a evaluar es la capacidad de la plataforma para integrarse con otras tecnologías. Es crucial que la plataforma no solo brinde la opción de descargar información, sino que también permita una interoperabilidad fluida y eficiente, facilitando su integración con otros sistemas y herramientas utilizadas en el entorno operativo. Esta capacidad de integración permite el intercambio de datos, la colaboración y la sincronización con otras plataformas o aplicaciones, lo que maximiza el valor y la utilidad de la información recopilada. La capacidad de la plataforma para interactuar de manera armoniosa con otras tecnologías es esencial para aprovechar al máximo las funcionalidades y recursos disponibles.
- Adaptabilidad y Estabilidad: En un entorno minero en constante evolución, las necesidades de los usuarios también cambian. Por tanto, es importante que las plataformas sean capaces de adaptarse y proporcionar la información y las herramientas que los usuarios demandan, anticipándose a sus necesidades. Un claro ejemplo de esta evolución es el creciente enfoque en la medición de estándares de sostenibilidad, donde los factores ambientales, sociales y de gobernanza (ASG) desempeñan un papel fundamental. Además, la estabilidad de la plataforma es esencial para garantizar un funcionamiento óptimo y sin interrupciones.
- Herramientas de Análisis: El objetivo es determinar si las herramientas y funcionalidades que ofrece la plataforma son relevantes para respaldar la toma de decisiones. Dentro de este criterio, se incluyen herramientas como búsquedas y consultas específicas, capacidad para generar informes y visualizaciones mediante la aplicación de técnicas analíticas avanzadas. Con estas herramientas, los usuarios pueden explorar y comprender los datos de manera más profunda, identificar patrones y tendencias, y tomar decisiones fundamentadas basadas en evidencia. La capacidad de análisis avanzado proporcionada por la plataforma es clave para obtener información valiosa y aprovechar al máximo los datos recopilados en el entorno minero.
- Precisión y Actualización: La precisión se refiere a la confiabilidad, consistencia y ausencia de errores en los datos. Para ello, se analizan las fuentes utilizadas para extraer la información y los procedimientos implementados para detectar errores. En el caso de plataformas que emplean herramientas de Inteligencia Artificial para predecir o extraer información, también se evalúa el rango de tolerancia a errores aceptable. Por otro lado, la actualización se refiere a la frecuencia con la que los datos se mantienen al día. Esto asegura que la plataforma proporcione información oportuna y relevante para respaldar la toma de decisiones de los usuarios.

Parámetros de Extensión de Data

Los siguientes parámetros son importantes para evaluar la amplitud y calidad de los datos proporcionados por las plataformas de análisis. Estos son algunos de los criterios utilizados por las áreas de finanzas e inversiones de las empresas mineras, gobiernos y grupos de interés para estimar los costos de capital, precios de commodities y tomar decisiones estratégicas.

- Cobertura Geográfica: Este parámetro se refiere a la extensión geográfica de la plataforma. Las operaciones mineras se llevan a cabo en diferentes regiones y países, por lo tanto, una plataforma con amplia cobertura proporcionará información detallada y actualizada sobre los proyectos mineros en todas las regiones.
- Recursos y Reservas: Contar con información clara y completa sobre los recursos y reservas identificables de los proyectos y operaciones mineras es fundamental para evaluar su potencial geológico y viabilidad. Esta información se convierte en un aliado estratégico para la toma de decisiones informadas.
- Producción: El detalle de la producción minera, incluyendo volúmenes y calidad de los minerales extraídos, así como la información de los principales actores del mercado, es crucial para realizar un seguimiento de los niveles de producción, identificar tendencias y pronosticar la oferta y demanda del mercado.
- Precios de Commodities: La disponibilidad de datos históricos de precios de los commodities es fundamental para aplicar diferentes modelos de estimación y realizar análisis de rentabilidad. Estos datos permiten realizar predicciones basadas en tendencias pasadas y evaluar la confiabilidad de los modelos de predicción. Además, facilitan el análisis de rentabilidad, estimación de ingresos y evaluación del desempeño financiero de las empresas mineras.
- Datos Macroeconómicos: Contar con datos macroeconómicos y de política gubernamental de los principales países productores de minerales permite predecir tendencias en el mercado global y factores impulsores de la oferta y demanda. Esta información es relevante para las áreas de finanzas e inversiones de las empresas mineras en la toma de decisiones estratégicas.
- Data Financiera: Este parámetro evalúa la disponibilidad de datos financieros de las empresas mineras más importantes. Se incluye información sobre la salud financiera de las empresas, análisis de rentabilidad, solvencia, gestión de costos y desempeño en el mercado bursátil. También se consideran las inversiones y desinversiones en activos fijos, como la adquisición o venta de propiedades y operaciones con terceras empresas.
- Análisis y Estadísticas: Este último parámetro se refiere al nivel de procesamiento de los datos proporcionados por la plataforma y la flexibilidad para crear informes y análisis personalizados. Esto puede incluir mapas interactivos con múltiples

capas de datos, gráficos, informes, análisis comparativos y modelos predictivos. Contar con herramientas de análisis avanzadas facilita la identificación de patrones, tendencias y riesgos en el mercado minero.

Selección de Plataformas

La selección de las plataformas proveedoras de datos y estadísticas se llevó a cabo siguiendo criterios rigurosos relacionados con el volumen, calidad y confiabilidad de los datos, así como la robustez de las fuentes de información y procesamiento de datos. Se incluyeron una variedad de plataformas, desde aquellas que ofrecen información básica para la creación de modelos de predicción, hasta aquellas con servicios más sofisticados que proporcionan análisis personalizados, predicciones y recomendaciones de inversión. Se priorizó la inclusión de plataformas que ofrecieran un amplio volumen de datos mineros para permitir un análisis exhaustivo y completo. Además, se evaluó la calidad de la información suministrada por cada plataforma, verificando la precisión y confiabilidad de los datos. Se consideraron también las fuentes de información utilizadas y los procesos de validación y verificación implementados para garantizar la integridad de los datos.

Es importante destacar que la mayoría de las plataformas seleccionadas hacen uso de herramientas y modelos de aprendizaje automático. Sin embargo, es importante señalar que cada plataforma tiene diferentes niveles de automatización en la gestión de datos y los servicios ofrecidos a los clientes. Con esta selección cuidadosa de plataformas, se busca proporcionar una evaluación completa y precisa de algunas de las opciones disponibles en el mercado.

Resultados

A continuación, se presentarán los resultados del análisis de parámetros en las Tablas 2 y 3, que brindan una representación visual de las diferencias entre las plataformas evaluadas en términos de sus características y capacidades. En el eje horizontal se encuentran los parámetros de eficiencia o extensión de datos comparados, mientras que en el eje vertical se muestra la lista de plataformas seleccionadas. La gama de colores utilizada va desde el verde oscuro, que indica que la plataforma cumple completamente con el parámetro, hasta el rojo, que indica que no cumple con el mismo. Los colores ámbar o amarillo señalan un cumplimiento parcial del criterio.

Tabla 3
Cuadro Comparativo por Parámetros de Eficiencia

| | Velocidad de Respuesta | Facilidad de Uso | Capacidad de Integración | Adaptabilidad y Escalabilidad | Herramientas de Análisis | Precisión y Actualización |
|--------------------------------|------------------------|------------------|--------------------------|-------------------------------|--------------------------|---------------------------|
| Bloomberg | | | | | | |
| S&P Global Market Intelligence | | | | | | |
| FactSet | | | | | | |
| Wood Mackenzie | | | | | | |
| Fitch Solutions | | | | | | |
| Prospector | | | | | | |
| TNM Marco Polo | | | | | | |
| CRU Group | | | | | | |
| Seequent | | | | | | |
| Fastmarkets | | | | | | |
| The Northern Miner Group | | | | | | |

Nota. La Tabla 3 muestra un gráfico de calor que realiza una comparación entre las plataformas seleccionadas para el análisis, en función de parámetros de eficiencia. Elaboración propia.

Tabla 4
Cuadro Comparativo por Parámetros de Extensión de Data

| | Cobertura Geográfica | Recursos y Reservas | Producción | Informes Técnicos y Notas de Prensa | Precios de Commodities | Data Macroeconómica | Data Financiera | Análisis y Estadística |
|--------------------------------|----------------------|---------------------|------------|-------------------------------------|------------------------|---------------------|-----------------|------------------------|
| S&P Global Market Intelligence | | | | | | | | |
| Bloomberg | | | | | | | | |
| Wood Mackenzie | | | | | | | | |
| FactSet | | | | | | | | |
| Fitch Solutions | | | | | | | | |
| TNM Marco Polo | | | | | | | | |
| CRU Group | | | | | | | | |
| Prospector | | | | | | | | |
| The Northern Miner Group | | | | | | | | |
| Seequent | | | | | | | | |
| Fastmarkets | | | | | | | | |

Nota. La Tabla 4 muestra un gráfico de calor que realiza una comparación entre las plataformas seleccionadas para el análisis, en función de parámetros de extensión de datos. Elaboración propia.

Es importante tener en cuenta que el objetivo principal del análisis fue evaluar las capacidades de predicción y análisis de las plataformas, especialmente en relación con las necesidades y requerimientos de hedgers, gobiernos, empresas mineras y otros grupos de interés en la industria minera. Sin embargo, es crucial considerar que las valoraciones y resultados presentados pueden ser subjetivos y dependen de los objetivos específicos de cada lector. La inclusión de las plataformas en el análisis no implica una preferencia o recomendación particular por parte del autor, sino que busca proporcionar una visión imparcial y objetiva de las diferencias y características de cada plataforma, permitiendo a los lectores tomar decisiones informadas según sus necesidades y objetivos específicos en el ámbito de la industria minera.

Pasos Estratégicos para Adoptar la Inteligencia Artificial en Finanzas

La implementación exitosa de algoritmos de Inteligencia Artificial requiere no sólo una adecuada infraestructura técnica, sino también una transformación en la cultura organizacional y el pensamiento estratégico de una compañía.

En el siguiente instructivo, se presentan una serie de pasos fundamentales con el objetivo de guiar a las empresas mineras hacia la implementación de Inteligencia Artificial en la toma de decisiones estratégicas.

Paso 1: Definir objetivos claros. El primer paso consiste en identificar los objetivos específicos que se desean lograr con la implementación de Inteligencia Artificial en un proceso determinado de la empresa minera. Por ejemplo, mejorar las estimaciones de precios de minerales, optimizar costos operativos o proporcionar recomendaciones estratégicas a los inversionistas.

Paso 2: Recopilar y preparar. En esta etapa, se requiere el trabajo conjunto entre el científico de datos y las áreas involucradas, como las de finanzas e inversiones de las empresas mineras. Posteriormente, se reúnen los datos relevantes para los objetivos establecidos, incluyendo datos macroeconómicos y de mercado provenientes de plataformas de datos confiables. Además, se combina esta información externa con datos recolectados internamente de las operaciones mineras. Asegurarse de que los datos estén limpios y listos para ser utilizados en los modelos de Inteligencia Artificial.

Paso 3: Seleccionar y entrenar. Luego, se evalúa una variedad de algoritmos de aprendizaje automático y aprendizaje profundo disponibles para seleccionar el más adecuado según los objetivos establecidos. Posteriormente, se comienza a entrenar los modelos utilizando los datos preparados en el Paso 2, realizando ajustes hasta obtener resultados precisos y confiables.

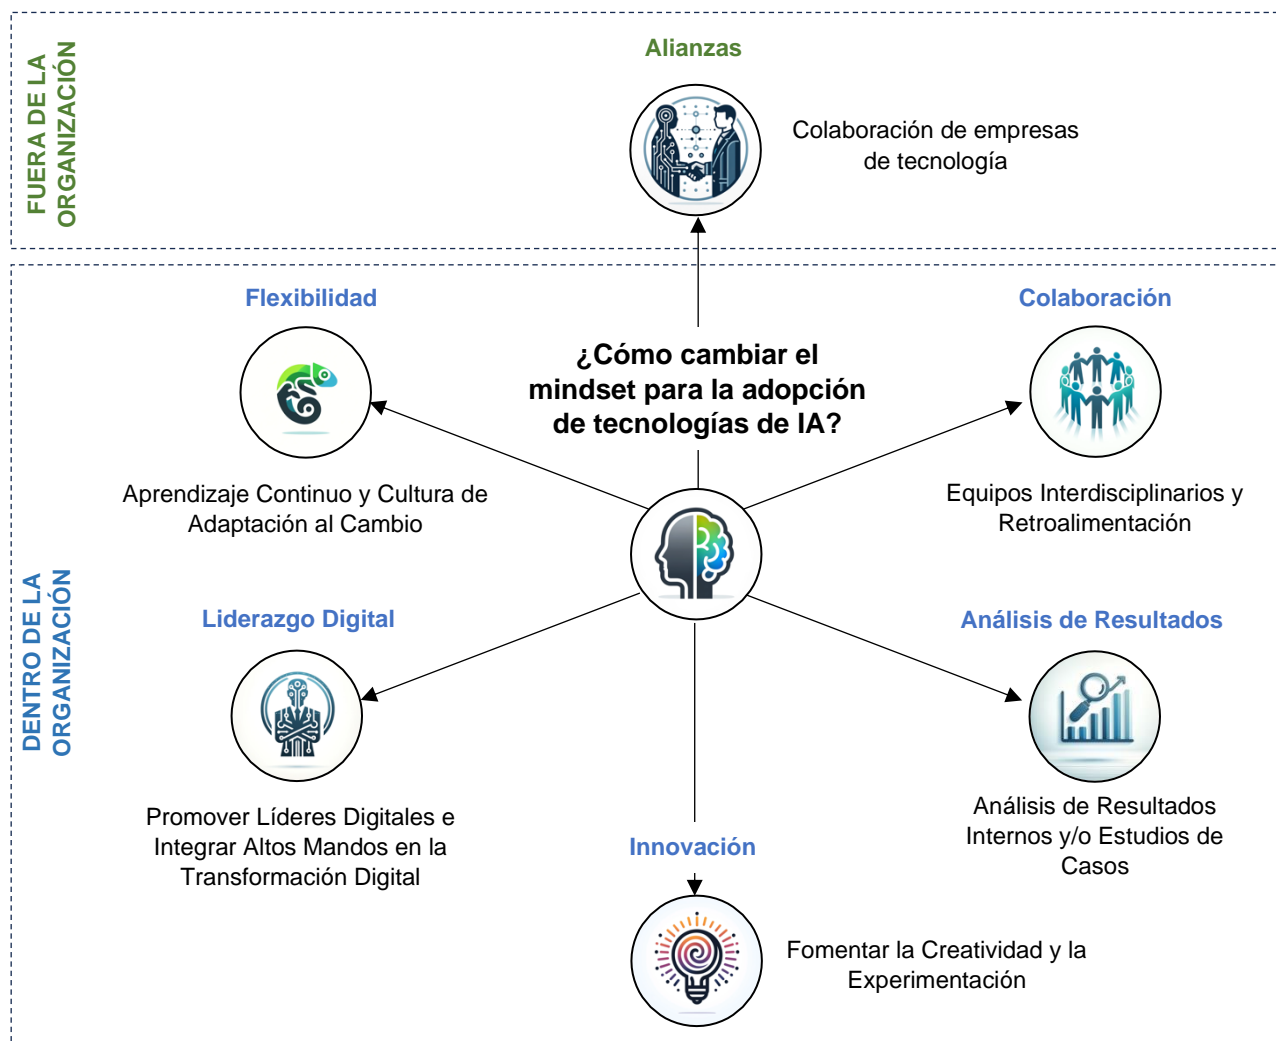
Paso 4: Integrar y validar. En esta etapa final de implementación, se ponen en marcha los modelos de Inteligencia Artificial en los procesos de toma de decisiones estratégicas del día a día para probar su eficacia y precisión. Se validan los modelos en situaciones reales y, de ser necesario, se realizan ajustes para optimizar los resultados.

Paso 5: Monitorear y actualizar. A pesar de que los modelos funcionen correctamente, es preciso establecer un sistema de monitoreo continuo para evaluar el rendimiento de los modelos de Inteligencia Artificial. Se deben mantener los modelos actualizados regularmente a medida que se recopilan nuevos datos o surjan cambios en las condiciones del mercado.

Una vez establecida la base práctica para la implementación de la Inteligencia Artificial, es esencial cultivar un cambio de mentalidad en los ejecutivos para potenciar su adopción en finanzas e inversiones. Este cambio implica pasar de una visión tradicional a una más innovadora, motivada por los beneficios tangibles que la Inteligencia Artificial ha demostrado en otras áreas de la empresa.

Figura 6

Fomentando una Cultura para la Adopción de Inteligencia Artificial en Todas las Áreas



Nota. La Figura 6 muestra las estrategias claves para integrar la Inteligencia Artificial en diversas áreas de la empresa. Se presentan recomendaciones prácticas para fomentar una mentalidad abierta hacia la tecnología y para superar barreras técnicas y culturales.

Elaboración propia.

Para cambiar el mindset de los ejecutivos de compañías mineras hacia la adopción de Inteligencia Artificial en finanzas e inversiones, es clave comenzar mostrando los beneficios tangibles que la Inteligencia Artificial ha aportado en las operaciones, como la mejora en la eficiencia y la reducción de costos. Esta evidencia puede actuar como un catalizador para su aplicación en áreas financieras, resaltando cómo las herramientas de Inteligencia Artificial permiten predicciones precisas y análisis de riesgos en tiempo real, elementos críticos también para las finanzas.

Además, es esencial adoptar un enfoque personalizado que considere las particularidades de cada empresa minera, utilizando soluciones de Inteligencia Artificial que se adapten a sus necesidades específicas, en lugar de aplicar soluciones genéricas. Implementar metodologías

ágiles que permitan iteraciones rápidas y ajustes basados en el feedback de los usuarios finales también puede acelerar la aceptación y optimizar los resultados. Finalmente, fortalecer la seguridad de los datos y la privacidad y promover una cultura de educación continua en Inteligencia Artificial pueden consolidar la confianza y el interés en su adopción.

Otro enfoque efectivo es el liderazgo por ejemplo, donde los altos ejecutivos se involucran directamente con la Inteligencia Artificial. La participación activa de la alta dirección en la integración de Inteligencia Artificial demuestra un compromiso serio con la transformación digital y puede motivar a otros niveles de la organización a seguir su ejemplo. Asimismo, alinear los incentivos de los ejecutivos con los resultados obtenidos a través de la Inteligencia Artificial puede fomentar una adopción más rápida y profunda.

Por último, la colaboración con expertos en Inteligencia Artificial y el establecimiento de asociaciones estratégicas con firmas tecnológicas pueden facilitar la transferencia de conocimientos y tecnología. Esto no solo proporciona acceso a soluciones de Inteligencia Artificial más avanzadas y personalizadas, sino que también ayuda a los ejecutivos a entender mejor las tendencias del mercado y las posibilidades futuras de la Inteligencia Artificial en el sector minero (Demyttenaere, y otros, 2023). Estas estrategias, combinadas, pueden robustecer significativamente la disposición hacia la innovación y el cambio positivo en la industria minera.

Conclusiones

- La Inteligencia Artificial y el aprendizaje automático han revolucionado la gestión de las operaciones mineras al permitir el procesamiento de grandes volúmenes de datos, la identificación de patrones complejos y la realización de predicciones más precisas y confiables. El uso del big data respaldado en línea proporciona una amplia gama de información que puede ser aprovechada para tomar decisiones fundamentadas en inversiones mineras y estrategias empresariales.
- Los algoritmos de aprendizaje automático y aprendizaje profundo son utilizados en la industria minera para predecir precios de commodities con precisión, lo cual es crucial para evaluar la viabilidad de proyectos y gestionar los riesgos asociados con la volatilidad de los precios.
- La Inteligencia Artificial también se utiliza para estimar y gestionar eficientemente los costos operativos y de capital en la industria minera, lo que permite una planificación y gestión más efectiva de los recursos financieros y la toma de decisiones basadas en datos confiables.
- Las plataformas de data e información en la industria minera ofrecen análisis avanzados y predicciones basadas en la Inteligencia Artificial, lo que brinda a las empresas mineras la capacidad de optimizar sus operaciones, mejorar la toma de decisiones y obtener una ventaja competitiva en el mercado.
- La adopción de la Inteligencia Artificial en las áreas de finanzas e inversiones de las compañías mineras implica un cambio de mentalidad estratégica y cultural en la organización. Los pasos detallados en este documento subrayan la importancia de una transformación integral que alinea la innovación tecnológica con los objetivos a largo plazo de la empresa.

Referencias

- Galan Zazo, J., Galan Ordox, J., & Turrion Diez, A. (2022). *El Futuro de la Investigación en Emprendimiento Estratégico: Inducción y Deducción a través del Machine Learning*. Burgos, España.
- Zhou, L., Shimei, P., Wang, J., & Vasilakos, A. (2017). *Machine learning on big data: Opportunities and challenges*. Baltimore, Maryland, United States: <https://doi.org/10.1016/j.neucom.2017.01.026>.
- Hachmi, B., Boubaker, S., Ftiti, Z., Louhichi, W., & Tissaoui, K. (2023). *Forecasting commodity prices: empirical evidence using deep learning tools*. <https://doi.org/10.1007/s10479-022-05076-6>.
- Zhang, H., Nguyen, H., Bui, X., Nguyen-Thoi, T., Bui, T., Nguyen, N., . . . Moayed, H. (2020). *Developing a novel artificial intelligence model to estimate the capital cost of mining projects using deep neural network-based ant colony optimization algorithm*. <https://doi.org/10.1016/j.resourpol.2020.101604>.
- Tapia Cortez, C., Saydam, S., Coulton, J., & Sammut, C. (2018). *Alternative techniques for forecasting mineral commodity prices*. NSW, Australia: <https://doi.org/10.1016/j.ijmst.2017.09.001>.
- Ghosh, I., Tamal Datta, C., Alfaro-Cortes, E., Gamez, M., & Garcia, N. (2022). *A hybrid approach to forecasting futures prices with simultaneous consideration of optimality in ensemble feature selection and advanced artificial intelligence*. <https://doi.org/10.1016/j.techfore.2022.121757>.
- Samis, M., & Steen, J. (2020). *Financial evaluation of mining innovation pilot projects and the value of information*. Canadá: <https://doi.org/10.1016/j.resourpol.2020.101848>.
- Tilton, J., & Guzman, J. (2016). *Mineral Economics and Policy*. New York: RFF Press.
- Kennedy, P. (2008). *A Guide to Econometrics*. Oxford, United Kingdom: Blackwell Publishing.
- Szarek, D., Bielak, Ł., & Wyłomańska, A. (2020). *Long-term prediction of the metals' prices using non-Gaussian time-inhomogeneous stochastic process*. Poland.
- Golebiowska, A., & Prokopowicz, D. (2021). *Business Intelligence analytics based on the processing of large sets of information with the use of sentiment analysis and Big Data*. Poland.
- Oracle. (2022). *The Evolution of Big Data and the Future of the Data Platform*. <https://www.oracle.com/a/ocom/docs/big-data/big-data-evolution.pdf>.
- Waller, M., & Fawcett, S. (2013). *Data Science, Predictive Analytics, and Big Data: A Revolution That Will Transform Supply Chain Design and Management*. Estados Unidos: <https://doi.org/10.1111/jbl.12010>.
- IBM Analytics. (2015). *Metodología Fundamental para la Ciencia de Datos*. Estados Unidos: <https://www.ibm.com/downloads/cas/6RZMKDN8>.
- Mullainathan, S., & Spiess, J. (2017). *Machine Learning: An Applied Econometric Approach*. <https://doi.org/10.1257/jep.31.2.87>.
- UC Berkeley School of Information. (2020, June 26). *What Is Machine Learning (ML)?* Retrieved Junio, 2023 from <https://ischoolonline.berkeley.edu/blog/what-is-machine-learning/>

- Mahesh, B. (2018). *Machine Learning Algorithms - A Review*. India.
- Zhang, H., Nguyen, H., Vu, D.-A., Bui, X.-N., & Pradhan, B. (2021). *Forecasting monthly copper price: A comparative study of various machine learning-based methods*. <https://doi.org/10.1016/j.resourpol.2021.102189>.
- Sami, I., & Nazir, K. (2018). *Predicting Future Gold Rates using Machine Learning Approach*. Pakistán: DOI: 10.14569/IJACSA.2017.081213.
- Liu, C., Hu, Z., Li, Y., & Shaojun, L. (2017). *Forecasting copper prices by decision tree learning*. China: <https://doi.org/10.1016/j.resourpol.2017.05.007>.
- Sarker1, I. (2021). *Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions*. Singapore: <https://doi.org/10.1007/s42979-021-00815-1>.
- Méndez-Suárez, M., García-Fernández, F., & Gallardo, F. (2019). *Artificial Intelligence Modelling Framework for Financial Automated Advising in the Copper Market*. Madrid, España.
- Nourali, H., & Osanloo, M. (2019). *A New Cost Model for Estimation of Open Pit Copper Mine Capital Expenditure*. Teran, Iran: doi: 10.5829/ije.2019.32.02b.21.
- Demyttenaere, M., Roos, A., Sheth, H., Rodt, M., Harris, M., Khodabandeh, S., . . . Grabowski, J. (2023, Agosto 22). *Generative AI in the Finance Function of the Future*. Retrieved Abril 2024, from Boston Consulting Group: <https://www.bcg.com/publications/2023/generative-ai-in-finance-and-accounting>
- Palacios, D. (2023, Enero 20). *Qué es el sentimiento del mercado y cómo se mide*. Retrieved Abril 2024, from Fintualist: <https://fintualist.com/chile/educacion-financiera/que-es-el-sentimiento-del-mercado-y-como-se-mide/>