

**Estudio de las aplicaciones de modelos de machine learning en la seguridad minera  
subterránea de carbón: una revisión bibliográfica**

Pedro Xavier Castilla Mangones

Asesor

Jose Laureano Cruz Cardozo

Universidad Nacional Abierta y a Distancia UNAD  
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI  
Especialización en Ciencia de Datos y Analítica

2024

## Resumen

Este estudio explora la aplicación de modelos de machine learning en la seguridad minera subterránea de carbón, destacando su potencial para mejorar la prevención y mitigación de riesgos. Se analizan diversos tipos de algoritmos y su implementación en la detección temprana de condiciones peligrosas, como explosiones de metano y acumulación de gases tóxicos.

Además, se evalúan tecnologías actuales y enfoques de gestión de seguridad en minería, subrayando el impacto positivo que tienen en la reducción de accidentes y la optimización de operaciones. La investigación proporciona un marco para futuras aplicaciones de inteligencia artificial en la industria minera, con el objetivo de fomentar un entorno más seguro y eficiente.

***Palabras claves:*** Machine learning, Seguridad minera, Análisis de riesgos, Gestión de datos, Prevención de accidentes.

## **Abstract**

This study explores the application of machine learning models in underground coal mining safety, highlighting their potential to improve risk prevention and mitigation. Various types of algorithms and their implementation in the early detection of hazardous conditions, such as methane explosions and toxic gas accumulation, are analyzed. Furthermore, current technologies and security management approaches in mining are evaluated, highlighting their positive impact on reducing accidents and optimizing operations. The research provides a framework for future applications of artificial intelligence in the mining industry, with the aim of fostering a safer and more efficient environment.

**Keywords:** Machine learning, Mining safety, Risk analysis, Data management, Accident prevention.

## Tabla de Contenido

Introducción .....	8
Justificación .....	9
Objetivos.....	10
Objetivo General .....	10
Objetivos Específicos.....	10
Marco Referencial.....	11
Generalidades y Conceptos Asociados a la Seguridad Minera Subterránea.....	11
Riesgos Comunes en Minería Subterránea.....	11
Accidentalidad en Minería .....	12
Tecnología de Seguridad en la Minería.....	14
Gestión de la Seguridad.....	15
Generalidades y Conceptos Asociados al Machine Learning.....	16
Tipos de Machine Learning.....	16
Algoritmos de Machine Learning Comunes en Minería.....	17
Machine Learning en la Industria Minera.....	18
Machine Learning en la Seguridad Minera Subterranea.....	21
Identificación de RiesgosRaíz en Minería Subterranea.....	21
Clasificación y Control de Accidentes en Minas de Carbón.....	21
Análisis de Estabilidad de Techos de Minas Mediante Acústica y Machine Learning .....	22
Análisis de Datos Masivos en la Seguridad Minera.....	22
Modelado de Causas de Accidentes Mediante Datos Históricos .....	23
Clasificación de Partículas Mediante Microscopia Óptica e Inteligencia Artificial .....	23

Análisis de Sensibilidad y Predicción de Material Particulado en Minas Subterránea .....	24
Aplicaciones de I.A. para Prevenir Accidentes por Gas en Minas Subterráneas.....	24
Técnicas de Machine Learning para Predecir Estallidos de Carbón y Gas.....	25
Modelos de Machine Learning para la Predicción de Deslizamientos Superficiales .....	26
Identificación de Zonas de Riesgo de Accidentes Mineros Usando Redes Neuronales .....	26
Inteligencia Artificial Aplicada a la Detección Riesgo de Explosión.....	27
Efectividad de Modelos de Machine Learning en la Prevención de Accidentes .....	28
Variables Clave en la Predicción de Riesgos .....	28
Precisión y Exactitud de las Predicciones.....	30
Capacidad de Generar Alertas Tempranas .....	31
Robustez de los Modelos Ante Ruido en los Datos .....	31
Interpretabilidad y Transparencia de los Modelos .....	32
Beneficios y Desafíos del Machine Learning en la Seguridad Minera.....	33
Beneficios de Implementar Machine Learning en la Seguridad Minera.....	33
Mejora en la Predicción de Riesgos y Prevención de Accidentes.....	33
Optimización de los Procesos Operativos .....	34
Monitorización y Respuesta en Tiempo Real.....	35
Desafíos de Implementar Machine Learning en la Seguridad Minera.....	35
Disponibilidad y Calidad de los Datos .....	35
Complejidad Técnica y Costos Iniciales .....	36
Problemas Éticos y Seguridad de los Datos .....	36
Adaptabilidad y Escalabilidad.....	37
Superación de Limitaciones Tradicionales.....	37

Conclusiones .....	39
Recomendaciones .....	40
Bibliografía .....	41

**Lista de Tablas**

**Tabla 1** *Sabana de Accidentalidad de 2005 a 2023* ..... 13

**Tabla 2** *Variables Clave Encontradas en los Casos de Estudio* ..... 28

## **Introducción**

Las aplicaciones de modelos de machine learning para mejorar la seguridad en la minería subterránea de carbón es un área de investigación con creciente relevancia debido a la necesidad de mitigar los riesgos inherentes a las operaciones mineras. La minería subterránea de carbón presenta numerosos desafíos relacionados con la seguridad, como deslizamientos, colapsos y la presencia de gases tóxicos. Tradicionalmente, las medidas de seguridad han sido gestionadas mediante métodos convencionales, los cuales dependen en gran medida de la experiencia humana. No obstante, con el avance de la ciencia de datos, los modelos predictivos basados en machine learning han demostrado ser herramientas valiosas para anticipar riesgos y mejorar la toma de decisiones.

Este estudio busca explorar y revisar cómo los modelos de machine learning pueden implementarse para mejorar la seguridad en las operaciones mineras subterráneas de carbón. Este enfoque es altamente relevante para la industria minera, ya que la implementación de sistemas de información robustos y eficientes es esencial para mejorar la seguridad y la eficiencia en las operaciones. Además, aporta significativamente a la resolución de problemas en el ámbito social y productivo, donde la minería es una actividad económica crucial y la seguridad de los trabajadores es una prioridad esencial.

## Justificación

La industria minera es una de las más peligrosas del mundo debido a la naturaleza de su entorno de trabajo y los riesgos inherentes que presenta, tales como deslizamientos de tierra, colapsos de túneles, y la presencia de gases tóxicos (Qiao & Chen, 2022). La seguridad minera no solo es una preocupación esencial para la protección de los trabajadores, sino también para la sostenibilidad operativa y económica de las compañías mineras. Tradicionalmente, las estrategias para mitigar estos riesgos han dependido de evaluaciones manuales y medidas preventivas basadas en la experiencia y la observación, las cuales pueden ser limitadas y subjetivas (Xuecai et al., 2024).

En este contexto, los modelos de machine learning han emergido como herramientas poderosas para mejorar la seguridad en la minería. Estos modelos pueden analizar grandes volúmenes de datos de manera eficiente, identificar patrones y predecir eventos peligrosos con alta precisión. Por ejemplo, técnicas de machine learning pueden ser utilizadas para detectar condiciones peligrosas en tiempo real (Liu et al, 2022).

La implementación de técnicas de machine learning en la minería ofrece numerosos beneficios, como la reducción de accidentes, la mejora de la salud y seguridad de los trabajadores, y la optimización de los costos operativos. Sin embargo, su adopción también presenta desafíos, incluyendo la necesidad de inversión en tecnología y capacitación, y la resistencia al cambio por parte del personal (You et al., 2021).

En ese sentido, este estudio se realiza con el fin de realizar una revisión bibliográfica exhaustiva de las aplicaciones de modelos de machine learning en la seguridad minera, con el fin de identificar y analizar las tecnologías y métodos más efectivos, así como evaluar sus beneficios y desafíos.

## **Objetivos**

### **Objetivo General**

Estudiar la pertinencia de las aplicaciones de modelos de machine learning en la mejora de la seguridad minera en minas de carbón.

### **Objetivos Específicos**

Analizar casos de estudio y proyectos que emplean machine learning.

Identificar los factores que influyen en la efectividad de los modelos de machine learning para la prevención de accidentes.

Estudiar posibles beneficios y desafíos de implementar machine learning en la seguridad minera.

## **Marco Referencial**

El uso de técnicas de machine learning se ha consolidado como un componente esencial dentro de la Ciencia de datos. En el ámbito minero, esta tecnología ofrece una ventaja competitiva al posibilitar análisis avanzados de grandes volúmenes de información, con aplicaciones directas en la predicción de riesgos y la mejora de la seguridad en minas subterráneas. En particular, la minería de carbón subterránea presenta condiciones peligrosas, como deslizamientos y la presencia de gases tóxicos, que requieren soluciones tecnológicas avanzadas para su monitoreo y prevención (Agencia Nacional de minería, 2021).

### **Generalidades y Conceptos Asociados a la Seguridad Minera Subterránea**

La seguridad minera es una disciplina fundamental que se enfoca en la prevención de accidentes y la protección de los trabajadores en entornos mineros. Debido a los numerosos riesgos inherentes a la minería, como deslizamientos, colapsos y la presencia de gases tóxicos, es crucial implementar medidas y tecnologías adecuadas para garantizar un ambiente de trabajo seguro (Molina et al., 2023). Este apartado aborda los conceptos y generalidades clave de la seguridad minera, proporcionando el marco teórico necesario para entender su importancia y aplicación en la industria del carbón subterráneo.

### ***Riesgos Comunes en Minería Subterránea***

La minería subterránea presenta numerosos riesgos inherentes que pueden afectar la seguridad y salud de los trabajadores. Estos riesgos están relacionados con la naturaleza del entorno subterráneo y las actividades mineras que se realizan. A continuación, se describen algunos de los riesgos más comunes en la minería subterránea (Agencia Nacional de minería, 2021).

**Deslizamientos y colapsos:** Los deslizamientos y colapsos de roca son riesgos significativos en la minería subterránea. Estos eventos pueden ser causados por la inestabilidad geológica, fallas en el soporte de las excavaciones y vibraciones provenientes de explosiones. La prevención de estos incidentes implica la implementación de métodos adecuados de sostenimiento, como el uso de pernos de anclaje y mallas de refuerzo (Ministerio de Minas y Energía, 2015).

**Gases tóxicos:** La acumulación de gases tóxicos, como el monóxido de carbono (CO), el dióxido de carbono (CO<sub>2</sub>) y el metano (CH<sub>4</sub>), es un riesgo crítico en las minas subterráneas. Estos gases pueden provocar asfixia, explosiones e incendios. Es esencial contar con sistemas de ventilación eficientes y dispositivos de monitoreo continuo para detectar y controlar la presencia de gases peligrosos (Ministerio de Minas y Energía, 2015).

**Explosiones y fuegos:** Las explosiones y fuegos pueden ocurrir debido a la presencia de gases inflamables, polvo de carbón y fallas en los procedimientos de voladura. La implementación de medidas preventivas, como la ventilación adecuada, el uso de equipos a prueba de explosiones y la capacitación en manejo de explosivos, es fundamental para reducir estos riesgos (Agencia Nacional de Minería, 2021).

### ***Accidentalidad en Minería***

La accidentalidad minera en Colombia es un desafío significativo que involucra a empresarios, titulares, directivos, trabajadores mineros y, en particular, a la Autoridad Minera. Este problema subraya la necesidad de diagnosticar y distribuir adecuadamente las responsabilidades de cada uno de estos actores en la prevención de accidentes. La Autoridad Minera desempeña un papel crucial al garantizar que los titulares mineros cumplan con las

normativas de seguridad, mediante procesos de fiscalización que incluyen evaluaciones documentales e inspecciones de campo (Barreto Caldón, 2024).

De acuerdo con la sabana de accidentalidad de la Agencia Nacional de Minería (Tabla 1), en el lapso de 2005 a 2023, se han registrado más de 1787 accidentes en la industria minera, resultando en el fallecimiento de 2058 trabajadores. Estos incidentes evidencian la necesidad de reforzar las estrategias de seguridad y monitoreo en el sector. Entre los accidentes más comunes, se destacan:

Accidentes por atmósfera contaminada: 118 heridos y 345 fallecidos.

Accidentes por fallas geomecánicas: 218 heridos y 562 fallecidos.

Accidentes por gas metano: 134 heridos y 368 fallecidos.

Accidentes por incendio: 53 heridos y 6 fallecidos.

La alta incidencia de accidentes asociados a atmósferas contaminadas, fallas geomecánicas y gases peligrosos refuerza la necesidad de implementar tecnologías avanzadas, como machine learning, para mejorar la prevención y respuesta ante estos riesgos .

### **Tabla 1**

*Sabana de Accidentalidad de 2005 a 2023*

Cantidad de accidentes registrados	Cantidad de personas involucradas	Cantidad de heridos	Cantidad de fallecidos
1787	4910	1003	2058

*Nota.* Representa el índice de accidentalidad de 2005 al 2023. Tomado de Agencia Nacional de minería.

### ***Tecnología de Seguridad en la Minería***

La industria minera ha adoptado diversas tecnologías para mejorar la seguridad en las operaciones subterráneas. Estas tecnologías ayudan a monitorear, detectar y mitigar riesgos, protegiendo así la salud y seguridad de los trabajadores. A continuación, se describen algunas de las tecnologías más relevantes en este ámbito.

**Sistemas de monitoreo y detección de gases:** Los sistemas de monitoreo de gases son esenciales para detectar la presencia de gases tóxicos e inflamables en las minas subterráneas. Estos sistemas utilizan sensores que miden continuamente los niveles de gases como el metano (CH<sub>4</sub>), el monóxido de carbono (CO) y el dióxido de carbono (CO<sub>2</sub>), entre otros gases. Los datos recogidos se analizan en tiempo real, permitiendo alertas tempranas y acciones preventivas (You et al., 2021).

**Sistemas de soporte de techo y control de estabilidad:** Para prevenir colapsos y deslizamientos de roca, se utilizan sistemas avanzados de soporte de techo que incluyen pernos de anclaje, mallas de refuerzo y arcos de acero. Estos sistemas están diseñados para proporcionar soporte estructural adicional y mejorar la estabilidad de las excavaciones. La monitorización geotécnica, mediante el uso de instrumentos como extensómetros y geófonos, permite evaluar la estabilidad de las formaciones rocosas y detectar movimientos subterráneos (Anani et al., 2024).

**Sistemas de comunicación y localización:** La comunicación efectiva y la localización precisa de los trabajadores son cruciales para la seguridad en las minas subterráneas. Los sistemas de comunicación modernos, como la comunicación de radio y los sistemas inalámbricos de banda ancha, permiten una comunicación clara y constante entre los trabajadores y los equipos de superficie. Además, los sistemas de localización en tiempo real (RTLS) utilizan

tecnología GPS y RFID para rastrear la ubicación de los trabajadores y equipos, mejorando la coordinación y la respuesta ante emergencias (Yang et al., 2018).

### ***Gestión de la Seguridad***

La gestión de la seguridad en minas subterráneas es un proceso integral que incluye la identificación y evaluación de riesgos, el desarrollo de políticas y procedimientos de seguridad, la capacitación de los trabajadores, y la implementación de tecnologías avanzadas (Agencia Nacional de minería, 2021). Según la Guía Técnica Colombiana (GTC 45), es esencial realizar evaluaciones de riesgo sistemáticas para identificar y priorizar peligros como deslizamientos de tierra, explosiones de gases y fallas estructurales.

Desarrollar políticas y procedimientos claros, específicos y accesibles es fundamental para mitigar estos riesgos, y deben ser revisados y actualizados regularmente. La capacitación continua de los trabajadores en temas como procedimientos de emergencia, uso de equipos de protección personal (EPP), y prácticas de trabajo seguro es crucial para garantizar su comprensión y cumplimiento (Agencia Nacional de minería, 2021).

Se han desarrollado documentos técnicos encaminados a mejorar la gestión de la seguridad en las minas subterráneas, instruyendo de forma organizada cómo reconocer y evaluar riesgos de manera pertinente, con el fin de generar planes de acción para prevenirlos. Un ejemplo es la guía técnica desarrollada en 2021 por la Agencia Nacional de Minería y la Universidad Nacional de Colombia, enfocada en el diseño de un plan de prevención y mitigación de explosiones de metano y polvo de carbón en minas de carbón. Otro ejemplo es la guía técnica creada por el Laboratorio Oficial J.M. Madariaga en España. Ambas guías presentan metodologías prácticas para abordar los riesgos mencionados anteriormente.

## **Generalidades y Conceptos Asociados al Machine Learning**

El machine learning, una rama fundamental de la inteligencia artificial se enfoca en desarrollar algoritmos y modelos informáticos que permiten que las computadoras aprendan y mejoren automáticamente a partir de la experiencia, sin necesidad de ser programadas explícitamente para cada tarea en particular (Hastie, Tibshirani & Friedman, 2009). Este campo ha revolucionado múltiples industrias al proporcionar herramientas para el análisis predictivo y la toma de decisiones basadas en datos. A continuación, se presentan algunas generalidades y conceptos clave que sustentan esta tecnología.

### ***Tipos de Machine Learning***

El machine learning se clasifica en varios tipos, dependiendo de la naturaleza de los datos y el objetivo del aprendizaje. Los dos tipos más comunes son el aprendizaje supervisado y el aprendizaje no supervisado.

**Aprendizaje supervisado:** en el aprendizaje supervisado, el algoritmo aprende a partir de un conjunto de datos que ya están etiquetados con la respuesta deseada o la salida correcta. Esto significa que cada entrada en el conjunto de datos de entrenamiento viene acompañada de su correspondiente salida. El propósito del aprendizaje supervisado es crear un modelo que pueda predecir correctamente la salida para nuevas instancias basándose en las entradas y salidas conocidas del conjunto de datos de entrenamiento (Valenzuela, 2022).

**Aprendizaje no supervisado:** el aprendizaje no supervisado se aplica a conjuntos de datos que no están etiquetados con respuestas conocidas o salidas específicas. En este caso, el objetivo principal es identificar patrones o estructuras inherentes en los datos sin la necesidad de contar con salidas predefinidas como guía. El aprendizaje no supervisado se utiliza comúnmente para

tareas como el agrupamiento (clustering) y la reducción de dimensionalidad (Hastie, Tibshirani & Friedman, 2009).

### ***Algoritmos de Machine Learning Comunes en Minería***

El campo del machine learning utiliza una variedad de algoritmos para resolver distintos problemas. A continuación, se describen algunos de los algoritmos más comunes y su aplicación en diferentes contextos.

**Regresión Lineal y Regresión Logística:** La regresión lineal es un algoritmo de aprendizaje supervisado que se emplea para predecir un valor de carácter continuo basado en la relación lineal entre las variables independientes y la variable dependiente. Por otro lado, la regresión logística se emplea para problemas de clasificación binaria, donde la salida es una probabilidad que determina la pertenencia de una instancia a una de dos clases posibles (James et al., 2013).

**Árboles de decisión y Bosques Aleatorios:** Los árboles de decisión son modelos de predicción que dividen iterativamente el espacio de características en subespacios más pequeños y homogéneos, basándose en ciertas condiciones. Los bosques aleatorios, o random forests, son una mejora de los árboles de decisión que utilizan un conjunto de árboles de decisión entrenados con diferentes partes del conjunto de datos y combinan sus resultados para mejorar la precisión y reducir el sobreajuste (Kane, 2017).

**Redes Neuronales y Deep Learning:** Las redes neuronales artificiales (ANN) están inspiradas en la estructura del cerebro humano y se utilizan para modelar relaciones complejas entre entradas y salidas. El deep learning es una subcategoría de las ANN que utiliza múltiples capas ocultas para aprender representaciones jerárquicas de los datos. Este enfoque ha

demostrado ser particularmente efectivo en tareas como el reconocimiento de imágenes y el procesamiento del lenguaje natural (LeCun, Bengio & Hinton, 2015).

**Maquinas de soporte Vectorial (SVM):** Las máquinas de soporte vectorial son algoritmos de clasificación cuyo objetivo es encontrar el hiperplano que mejor separa las clases en el espacio de características. Este algoritmo es conocido por su efectividad en problemas de clasificación de alta dimensión y su capacidad para manejar casos donde las clases no son linealmente separables mediante el uso de núcleos (kernels) (Kane, 2017).

**K-Means y K-Medoides:** K-means es uno de los algoritmos más conocidos, donde de manera iterativa se asignan los elementos a los K centroides según su proximidad, recalculando posteriormente el centro de cada grupo y repitiendo el proceso hasta converger. Está diseñado para trabajar con variables continuas y utiliza la distancia euclidiana al cuadrado para medir la disimilitud entre elementos. Por otro lado, K-medoides es una generalización de K-means que no se limita a una medida específica de disimilitud para encontrar los centros y asignar los elementos a los clústeres. Este algoritmo busca minimizar la suma de las disimilitudes entre los puntos asignados a un clúster y el punto designado como su centro. A pesar de esta mejora, sigue siendo vulnerable a los valores atípicos, por lo que es recomendable eliminarlos cuando se detectan (Fandango, 2018).

### **Machine Learning en la Industria Minera**

El machine learning ha emergido como una herramienta poderosa en la industria minera, ofreciendo soluciones innovadoras para optimizar procesos y mejorar la seguridad y eficiencia operativa. La capacidad de los algoritmos de machine learning para analizar grandes volúmenes de datos, identificar patrones y hacer predicciones precisas ha llevado a su aplicación en diversas áreas de la minería.

Durante la fase de exploración minera, el machine learning se emplea para evaluar datos geológicos y geofísicos, permitiendo la identificación de áreas con altas probabilidades de contener depósitos minerales. Esto facilita que las empresas mineras enfoquen sus esfuerzos y recursos en las zonas más prometedoras, lo que reduce tanto los costos como los tiempos de exploración (Jordan & Mitchell, 2015).

Además, los modelos de machine learning se aplican en el mantenimiento predictivo de maquinaria y equipos mineros. Mediante el análisis de datos en tiempo real provenientes de sensores instalados en los equipos, estos algoritmos pueden predecir fallas y recomendar mantenimientos antes de que ocurran averías costosas. Esto no solo disminuye el tiempo de inactividad, sino que también reduce significativamente los costos de reparación (Ng & Mishra, 2018).

Además de estos beneficios operativos, los modelos de machine learning también son útiles en la gestión ambiental. Pueden monitorear el impacto de las actividades mineras en el entorno y proponer medidas para minimizar daños. Por ejemplo, estos modelos pueden predecir la dispersión de contaminantes en el aire y el agua, ayudando a implementar estrategias de mitigación efectivas y así contribuir a la sostenibilidad de las operaciones mineras (Alvarez et al., 2020).

Por otro lado, la eficiencia de la producción minera puede ser significativamente mejorada a través del uso de algoritmos de machine learning para optimizar la asignación de recursos y la planificación de la producción. Esto incluye la gestión de la logística, el control de calidad del mineral extraído y la coordinación de diferentes etapas del proceso productivo (Samanta et al., 2016).

Finalmente, el machine learning también juega un papel crucial en la mejora de la seguridad en las minas. Modelos predictivos pueden detectar condiciones peligrosas, como acumulaciones de gases tóxicos o riesgos de colapso, y alertar a los trabajadores y supervisores para que tomen medidas preventivas. Además, la visión por computadora se utiliza para monitorear el comportamiento de los trabajadores, asegurando el cumplimiento de las normas de seguridad y reduciendo así el riesgo de accidentes (Fa et al., 2024).

## **Machine Learning en la Seguridad Minera Subterránea**

La integración de técnicas de machine learning en la seguridad minera ha demostrado ser fundamental para reducir los riesgos asociados a las operaciones subterráneas. A través de diversos estudios y aplicaciones prácticas, se han implementado soluciones que permiten la identificación temprana de condiciones peligrosas, optimización del monitoreo de la infraestructura minera y mejoras en los procesos de toma de decisiones.

### **Identificación de Riesgos Raíz en Minería Subterránea**

Fa et al. (2021) abordaron la identificación de riesgos raíz en minería subterránea de carbón mediante el uso de árboles de decisión, una técnica de machine learning aplicada para optimizar la gestión de riesgos. Este estudio se centró en la identificación de características críticas relacionadas con los comportamientos inseguros de los trabajadores, los cuales se consideran los principales desencadenantes de accidentes en la minería. Los autores analizaron variables como el departamento, la edad, los antecedentes educativos y el nivel de capacitación de los mineros. Los resultados mostraron que los árboles de decisión eran efectivos para identificar patrones de comportamiento que predecían situaciones de riesgo, lo que permitió mejorar la implementación de medidas preventivas en el entorno minero. Además, el estudio sugiere que optimizar la identificación de estos riesgos puede reducir significativamente la tasa de accidentes en operaciones subterráneas.

### **Clasificación y Control de Accidentes en Minas de Carbón**

Miao et al. (2021) investigaron el uso de métodos de machine learning para clasificar y controlar los accidentes en minas subterráneas de carbón. El estudio se basó en el análisis de 685 informes de accidentes, y empleó métodos como las redes complejas y el agrupamiento K-means para clasificar los tipos de accidentes y sus causas subyacentes. Los 29 factores considerados en

el análisis incluían fallas de equipo, condiciones ambientales y factores humanos. La clasificación de los accidentes permitió a los autores proponer medidas de control específicas para cada categoría de riesgo. El uso del clustering facilitó la identificación de patrones ocultos entre los diferentes tipos de accidentes, lo que ayudó a optimizar las estrategias de seguridad y a reducir el riesgo de accidentes futuros en las minas de carbón.

### **Análisis de Estabilidad de Techos de Minas Mediante Acústica y Machine Learning**

Wiens e Islam (2021) aplicaron técnicas de machine learning como PCA, regresión lineal y máquinas de soporte vectorial para analizar las grabaciones de impactos acústicos generados en los techos de las minas subterráneas de carbón. El objetivo de este estudio fue clasificar automáticamente el estado de los techos, determinando si presentaban riesgos de colapso. Se utilizaron un total de 36,000 grabaciones de sonido, lo que permitió a los investigadores extraer características clave relacionadas con la frecuencia y magnitud de los impactos. Estos datos fueron alimentados en modelos predictivos que lograron clasificar de manera precisa el estado de los techos, eliminando así la necesidad de inspecciones manuales que podrían ser peligrosas. El estudio concluyó que este método no solo mejora la seguridad en las minas, sino que también optimiza los tiempos de inspección y reduce los costos asociados a las revisiones tradicionales.

### **Análisis de Datos Masivos en la Seguridad Minera**

Qiao y Chen (2022) propusieron un enfoque novedoso para redefinir la connotación de los datos masivos en el ámbito de la seguridad minera, utilizando técnicas avanzadas de minería de datos y análisis de texto. A través del análisis de grandes volúmenes de datos provenientes de sensores, informes de accidentes y comportamientos de los trabajadores, los autores exploraron cómo estos datos podían ser utilizados para identificar patrones de riesgo en tiempo real. Aunque no se menciona un tamaño de muestra específico, los resultados indicaron que los modelos

predictivos basados en el análisis de datos masivos pueden mejorar significativamente la prevención de accidentes en minas subterráneas, al identificar comportamientos inseguros antes de que estos desencadenen incidentes. Esto no solo permite reaccionar rápidamente ante situaciones peligrosas, sino que también ayuda a implementar estrategias preventivas basadas en la monitorización constante.

### **Modelado de Causas de Accidentes Mediante Datos Históricos**

Xuecai et al. (2020) llevaron a cabo un estudio exhaustivo sobre las causas de accidentes en minas de carbón en China, utilizando datos históricos de incidentes para desarrollar modelos predictivos basados en el análisis de componentes principales (PCA), regresión y técnicas de clustering. A partir de esta información, los autores lograron agrupar los accidentes en varias categorías clave y correlacionar las causas con variables como la capacitación en seguridad, la antigüedad laboral y las condiciones de trabajo. El estudio reveló que la falta de capacitación adecuada era uno de los factores más influyentes en la ocurrencia de accidentes, lo que resalta la necesidad de mejorar los programas de formación en seguridad minera. Además, los modelos predictivos propuestos permitieron a los investigadores identificar con mayor precisión qué factores contribuyen a cada tipo de accidente, lo que facilita la toma de decisiones para la implementación de medidas preventivas más efectivas.

### **Clasificación de Partículas Mediante Microscopía Óptica e Inteligencia Artificial**

Santa et al. (2021) emplearon técnicas de procesamiento de imágenes y machine learning para clasificar partículas de polvo presentes en el ambiente de trabajo de las minas subterráneas de carbón. A través de la microscopía óptica, los autores analizaron muestras de polvo y, utilizando algoritmos de clasificación, lograron identificar si las partículas eran potencialmente dañinas para la salud de los trabajadores. Esta metodología permitió un monitoreo automatizado

de la calidad del aire, facilitando la detección temprana de partículas peligrosas. El estudio concluyó que la inteligencia artificial aplicada al análisis de imágenes microscópicas puede ser una herramienta eficaz para prevenir enfermedades relacionadas con la inhalación de polvo, al permitir una identificación más rápida y precisa de contaminantes en el aire.

### **Análisis de Sensibilidad y Predicción de Material Particulado en Minas Subterránea**

Ray et al. (2023) investigaron la dispersión y acumulación de material particulado diésel (DPM) en minas subterráneas de carbón, un contaminante significativo en estas operaciones. El estudio empleó regresión multivariante y redes neuronales para predecir la concentración de DPM en tres minas subterráneas. Los autores analizaron la velocidad del aire, la distancia del punto de emisión y la temperatura para predecir la dispersión del material particulado.

Las técnicas empleadas demostraron que los niveles de DPM están fuertemente correlacionados con la ventilación de la mina y las condiciones operativas. Las redes neuronales artificiales resultaron más eficaces que la regresión multivariante para predecir las concentraciones de DPM. Este modelo puede ser una herramienta valiosa para mejorar la calidad del aire en minas, reduciendo la exposición de los trabajadores a partículas peligrosas. Sin embargo, el estudio menciona la necesidad de realizar más investigaciones para evaluar otros factores como la maquinaria y la topografía de la mina.

### **Aplicaciones de I.A. para Prevenir Accidentes por Gas en Minas Subterráneas**

You et al. (2021) analizaron la aplicación de técnicas avanzadas de inteligencia artificial para prevenir accidentes por gas en minas subterráneas de carbón. El enfoque principal del estudio fue el uso de reducción de dimensionalidad con t-SNE y optimización bayesiana para predecir la gravedad de los accidentes de gas. Aunque el tamaño de la muestra no se menciona

explícitamente, el trabajo recopiló datos reales sobre accidentes, describiendo tanto las condiciones del entorno de la mina como el comportamiento de los trabajadores.

Los autores demostraron que la inteligencia artificial puede identificar patrones críticos en los datos de accidentes, permitiendo una mejor prevención de eventos catastróficos. En particular, la optimización bayesiana fue clave para ajustar los modelos y reducir la complejidad de los datos. El estudio destacó la importancia de la recopilación precisa de datos geológicos y operativos para mejorar la precisión de los modelos predictivos. Sin embargo, los autores advirtieron que las condiciones geológicas variables pueden afectar el rendimiento de estos modelos en diferentes minas..

### **Técnicas de Machine Learning para Predecir Estallidos de Carbón y Gas**

Anani et al. (2022) investigaron los avances en la aplicación de técnicas de machine learning para predecir los estallidos de carbón y gas, que representan un grave riesgo en la minería subterránea de carbón. El estudio utilizó modelos como k-nearest neighbors, regresiones, PCA y análisis discriminante para abordar el problema. Aunque el estudio no menciona el tamaño de la muestra, los datos utilizados se centraron en características geológicas, niveles de gases y condiciones de la mina.

Los hallazgos mostraron que los estallidos de carbón y gas están altamente correlacionados con el ángulo de buzamiento de las capas de carbón, así como con las propiedades geológicas de las rocas circundantes. Los modelos predictivos desarrollados permitieron identificar áreas de riesgo elevado, lo que podría mejorar las medidas preventivas y de respuesta ante estos eventos. Sin embargo, los autores señalaron que los modelos requieren una mejora continua y una calibración con datos locales más específicos para aumentar su precisión.

### **Modelos de Machine Learning para la Predicción de Deslizamientos Superficiales**

Liu et al. (2022) presentaron un estudio centrado en el modelado de deslizamientos superficiales utilizando técnicas de machine learning. El estudio comparó la eficacia de diferentes modelos, incluidos la regresión lineal regularizada y las redes neuronales artificiales, para predecir la ocurrencia de deslizamientos en áreas mineras con pendientes pronunciadas. Aunque el tamaño de la muestra no se menciona explícitamente, los datos incluyeron características como la resistencia de la roca y factores topográficos.

Los resultados del estudio indicaron que la combinación de machine learning y datos geotécnicos puede mejorar significativamente la precisión de las predicciones de deslizamientos superficiales. Las redes neuronales artificiales mostraron un mejor rendimiento al manejar datos complejos no lineales en comparación con los modelos de regresión. Sin embargo, los autores también destacaron la necesidad de desarrollar algoritmos más eficientes para manejar grandes volúmenes de datos y optimizar los tiempos de respuesta.

### **Identificación de Zonas de Riesgo de Accidentes Mineros Usando Redes Neuronales**

Zhang et al. (2021) implementaron redes neuronales artificiales para identificar zonas de alto riesgo de accidentes en minas subterráneas de carbón. A través de la integración de datos sobre condiciones geológicas, presión de roca y registros de accidentes pasados, los autores crearon un modelo predictivo capaz de señalar áreas con mayor probabilidad de incidentes. El estudio se basó en una base de datos de más de 1,000 registros de accidentes, los cuales fueron utilizados para entrenar el modelo. Los resultados mostraron que las redes neuronales podían predecir con alta precisión los puntos críticos de riesgo, permitiendo a las empresas mineras implementar medidas preventivas específicas en las áreas más vulnerables. Este enfoque

optimiza el uso de recursos de seguridad y mejora significativamente la capacidad de respuesta frente a posibles desastres en las minas subterráneas.

### **Inteligencia Artificial Aplicada a la Detección Riesgo de Explosión**

Molina et al. (2023) abordaron el uso de la inteligencia artificial (IA) y otras tecnologías emergentes en la seguridad minera. El estudio se centró en cómo los datos recolectados de detectores de gases personales en minas subterráneas pueden ser utilizados mediante algoritmos de IA para predecir explosiones de metano. Específicamente, se desarrolló una red neuronal artificial capaz de identificar patrones críticos en la concentración de gases, la velocidad del viento y la presión en las minas.

El ejercicio se basó en el análisis de las condiciones que llevaron a una explosión de metano y polvo de carbón ocurrida en Tópaga, Boyacá, en 2021. Los resultados demostraron que el uso de redes neuronales puede alertar sobre posibles explosiones con un nivel de precisión del 97,1 %, lo que mejora significativamente las medidas preventivas y reduce el riesgo de accidentes fatales en minas subterráneas.

Este caso destaca la capacidad de la IA para manejar grandes volúmenes de datos en tiempo real, mejorando la seguridad minera al anticipar eventos potencialmente catastróficos y contribuyendo a la protección de los trabajadores.

## Efectividad de Modelos de Machine Learning en la Prevención de Accidentes

El uso de machine learning (ML) para la prevención de accidentes en la industria minera ha mostrado resultados prometedores, ya que permite la identificación temprana de situaciones de riesgo y la predicción de eventos peligrosos con mayor precisión que los enfoques tradicionales. Para evaluar la efectividad de estos modelos, se pueden considerar los siguientes factores:

### Variables Clave en la Predicción de Riesgos

El éxito de los modelos de machine learning para prevenir accidentes depende en gran medida de las variables que se emplean para entrenar los algoritmos. En los estudios revisados, se identifican varias variables clave relacionadas con los riesgos operativos y de seguridad en la minería subterránea. Estas variables abarcan tanto factores técnicos como factores humanos que influyen directamente en la probabilidad de un accidente. En la Tabla 2 se describe algunas de las variables más relevantes y las técnicas de machine learning asociadas a su análisis.

**Tabla 2**

*Variables Clave Encontradas en los Casos de Estudio*

Variable Característica	Técnica de Machine Learning Asociada	Descripción
Nivel de comportamiento inseguro	Random Forest	Es crucial para predecir accidentes y mejorar la seguridad en la mina. Análisis de comportamiento inseguro ayuda a implementar medidas preventivas.
Factores del macizo rocoso	Random Forest, K-nn, Máquinas Vectoriales, PCA, Análisis de Sensibilidad, Regresión Lineal.	Son esenciales para evaluar el riesgo de colapsos y otros accidentes geotécnicos. Su análisis mejora la estabilidad y seguridad de las operaciones mineras.

Concentración de material particulado	Random Forest y Redes Neuronales	Es una variable crítica en la minería subterránea ya que afecta la salud de los trabajadores. Monitoreo y predicción pueden mejorar las condiciones de trabajo y seguridad.
Factores de accidentalidad humanos	Clustering y PCA	Son vitales para desarrollar estrategias de prevención de accidentes. Analizar estos factores puede mejorar la predicción y prevención de incidentes.
Factores de accidentalidad no humanos	Clustering y PCA	Importantes para entender todas las causas de accidentes, incluyendo aquellas no relacionadas directamente con el comportamiento humano.
Factor de seguridad de estabilidad de túneles	Redes Neuronales	Es crucial para la planificación y diseño seguro de túneles, evitando colapsos y mejorando la seguridad operativa.
Concentración de gases	K-nn, PCA, Redes neuronales, regresiones	Es fundamental en la minería subterránea ya que se asocia a el riesgo de incendios y explosiones así como también la intoxicación del personal.

*Nota.* Variables claves asociadas a riesgos en minería y técnicas de machine learning empleadas.

Estas variables juegan un papel crucial en los modelos de machine learning, ya que su correcto análisis y modelado permiten identificar de manera más precisa las situaciones de riesgo, facilitando la implementación de medidas preventivas antes de que ocurran accidentes. Cada una de estas técnicas ha sido probada en diversos estudios con diferentes niveles de

efectividad, demostrando la flexibilidad y potencial de machine learning para abordar los desafíos de seguridad en entornos de alta peligrosidad como la minería subterránea.

### **Precisión y Exactitud de las Predicciones**

La precisión y exactitud son dos indicadores esenciales para medir la efectividad de cualquier modelo de machine learning aplicado a la prevención de accidentes. La precisión hace referencia a la capacidad del modelo para predecir correctamente los eventos, mientras que la exactitud implica qué tan cerca están las predicciones del valor real (Hastie, Tibshirani & Friedman, 2009).

Los modelos de machine learning funcionan al entrenarse con datos históricos que contienen patrones de comportamiento previos a un accidente. Este entrenamiento les permite identificar correlaciones y dependencias entre múltiples variables que a menudo son invisibles para los métodos tradicionales. Entre los modelos más utilizados para este propósito se encuentran los árboles de decisión, las redes neuronales y los métodos de clasificación basados en regresión (Kane, 2017). Estos algoritmos se destacan por su capacidad para manejar una gran cantidad de datos, categorizarlos y hacer predicciones con base en relaciones no lineales entre las variables.

Sin embargo, la efectividad de estos modelos depende de su habilidad para minimizar los falsos positivos y falsos negativos. Un falso positivo podría llevar a la toma de medidas innecesarias, mientras que un falso negativo puede derivar en la falta de acción ante un riesgo inminente (Fawcett, 2006). Por lo tanto, la efectividad del modelo no solo se evalúa por la cantidad de predicciones correctas, sino también por su capacidad para generar un balance adecuado entre sensibilidad (verdaderos positivos) y especificidad (verdaderos negativos).

## **Capacidad de Generar Alertas Tempranas**

Un aspecto crucial de la efectividad de los modelos de machine learning en entornos de alto riesgo, como la minería, es su capacidad para generar alertas tempranas. Estos sistemas predicen accidentes potenciales con suficiente antelación, permitiendo que las medidas preventivas sean implementadas antes de que ocurra el evento (Xuecai et al, 2020).

Los algoritmos basados en regresión logística, random forests y modelos de series temporales son particularmente adecuados para esta tarea. Utilizan datos continuos, como el monitoreo de sensores y otros sistemas automatizados dentro de las minas, para predecir patrones que indiquen un aumento en el riesgo (Fa et al., 2021). Un buen sistema de alerta temprana debe ser capaz de analizar tanto datos históricos como en tiempo real, identificando cambios sutiles en las condiciones que podrían desencadenar un accidente.

La capacidad de respuesta del sistema es fundamental para su éxito. Un modelo que genera una alerta demasiado tarde puede ser prácticamente inútil en la prevención de accidentes, ya que los eventos se desarrollan rápidamente en entornos dinámicos como la minería subterránea. Además, la confiabilidad de estas alertas es crítica, demasiadas alertas falsas pueden generar fatiga en los trabajadores, reduciendo la efectividad del sistema en situaciones reales de emergencia.

## **Robustez de los Modelos Ante Ruido en los Datos**

Evaluar la robustez de los modelos frente al ruido en los datos es una forma de medir la efectividad. En ambientes mineros, los datos que se recogen a través de sensores y otros dispositivos de monitoreo pueden estar afectados por ruido o errores, debido a la interferencia de condiciones ambientales extremas, como vibraciones, polvo o interferencias electromagnéticas.

Un modelo robusto es capaz de distinguir entre patrones de datos reales y ruido, lo que le permite seguir haciendo predicciones precisas incluso en condiciones adversas. Técnicas como el uso de filtros (por ejemplo, el filtro de Kalman) o el aprendizaje supervisado con conjuntos de datos balanceados y ruidosos son fundamentales para asegurar que el sistema no genere falsas alarmas debido al ruido, ni omita eventos críticos por falta de claridad en los datos recibidos. Evaluar la capacidad del modelo para mantener su desempeño en presencia de ruido es una medida clave de su efectividad (García, Luengo, & Herrera, 2015).

### **Interpretabilidad y Transparencia de los Modelos**

Otra métrica clave en la efectividad de los modelos de machine learning es su interpretabilidad y transparencia. En la minería, la seguridad de los trabajadores depende no solo de que los modelos hagan predicciones precisas, sino también de que los expertos puedan comprender y confiar en esas predicciones. Los modelos más efectivos son aquellos que no actúan como cajas negras, sino que proporcionan explicaciones claras sobre por qué se ha generado una alerta o predicción.

Los modelos de machine learning como los árboles de decisión o los modelos basados en reglas tienden a ser más interpretables, ya que permiten a los usuarios visualizar y seguir el proceso de toma de decisiones del modelo. Asimismo, las técnicas de explicabilidad de modelos como LIME (Local Interpretable Model-Agnostic Explanations) o SHAP (SHapley Additive exPlanations) permiten a los ingenieros de seguridad comprender cómo y por qué el modelo llegó a una determinada conclusión, lo que facilita la implementación de medidas preventivas basadas en los resultados del modelo (Ribeiro, Singh & Guestrin, 2016).

## **Beneficios y Desafíos del Machine Learning en la Seguridad Minera**

La implementación de modelos de machine learning (ML) en la minería subterránea ofrece una serie de ventajas clave, pero también enfrenta retos significativos. A medida que la industria minera busca aumentar la seguridad de los trabajadores y optimizar sus operaciones, es fundamental analizar los beneficios que el ML puede proporcionar, así como los desafíos técnicos, organizacionales y éticos que esta tecnología plantea.

### **Beneficios de Implementar Machine Learning en la Seguridad Minera**

A continuación, se presentan diversos beneficios asociados a la implementación del machine learning en la seguridad minera.

#### ***Mejora en la Predicción de Riesgos y Prevención de Accidentes***

El objetivo principal de implementar modelos de machine learning en la prevención de accidentes es disminuir su ocurrencia mediante la predicción temprana de riesgos. A través del procesamiento de grandes volúmenes de datos provenientes de diversas fuentes, como sensores, equipos de minería y registros, se pueden identificar patrones que resultan difíciles de detectar con enfoques tradicionales. Esto permite que los sistemas predictivos anticipen posibles accidentes antes de que ocurran, brindando así el tiempo necesario para adoptar medidas preventivas.

Los modelos de machine learning han demostrado ser efectivos en reducir accidentes al proporcionar información más precisa y oportuna sobre las condiciones de trabajo peligrosas. Por ejemplo, modelos como las redes neuronales permiten analizar grandes volúmenes de datos de sensores instalados en las minas, identificando patrones de desgaste en equipos o variaciones peligrosas en las condiciones geotécnicas (Molina et al., 2023). Estos modelos, al ser entrenados adecuadamente, pueden predecir fallos de equipos, riesgos geológicos o problemas relacionados

con la salud ocupacional (como la exposición prolongada a gases tóxicos), lo que permite implementar acciones correctivas antes de que se produzcan incidentes.

Desde el punto de vista económico, la reducción de accidentes implica una menor cantidad de interrupciones no planificadas y una mejora en la continuidad operativa.

Adicionalmente, la adopción de sistemas de machine learning puede reducir significativamente los costos asociados a la supervisión y mantenimiento preventivo, ya que las predicciones más precisas permiten que estas actividades se realicen de manera más eficiente y dirigida (Fawcett, 2006)

### ***Optimización de los Procesos Operativos***

Modelos de machine learning puede ayudar a gestionar de manera más eficiente los equipos y el personal, ya que es capaz de detectar ineficiencias operativas que podrían aumentar los riesgos. Por ejemplo, los modelos de machine learning pueden monitorear el desgaste de la maquinaria en tiempo real y predecir cuándo se necesita mantenimiento, lo que ayuda a evitar fallos inesperados que podrían poner en peligro a los trabajadores y a las operaciones.

Esta capacidad de realizar un mantenimiento predictivo no solo mejora la seguridad, sino que también reduce los costos operativos. Al prevenir paradas no planificadas y fallos catastróficos de los equipos, las minas pueden mantener una mayor continuidad en sus operaciones, lo que también incrementa la productividad. Este tipo de optimización resulta en una disminución de las tasas de accidentes vinculados a la fatiga o malfuncionamientos de los equipos, lo cual es crítico en entornos donde las condiciones de trabajo son peligrosas (Bishop, 2006)

### ***Monitorización y Respuesta en Tiempo Real***

Los sistemas de machine learning se destacan por su capacidad para monitorear en tiempo real las condiciones de las minas. Esto es particularmente importante en ambientes subterráneos, donde los cambios repentinos en las condiciones del terreno, la calidad del aire o el comportamiento de los equipos pueden representar riesgos graves. Al estar conectados a una red de sensores y sistemas de información, estos modelos pueden procesar grandes volúmenes de datos de manera continua, generando alertas automáticas ante cualquier anomalía.

Por ejemplo, el monitoreo continuo de la concentración de gases peligrosos, como el metano o el dióxido de carbono, es esencial en minas subterráneas, donde una concentración demasiado alta puede resultar en explosiones o envenenamiento. Los modelos de machine learning pueden predecir estas condiciones peligrosas antes de que alcancen niveles críticos, lo que permite a los operadores tomar medidas correctivas inmediatas, como la evacuación de los trabajadores o la ventilación de las áreas afectadas (You et al., 2021).

### **Desafíos de Implementar Machine Learning en la Seguridad Minera**

A continuación, se presentan diversos desafíos asociados a la implementación del machine learning en la seguridad minera.

#### ***Disponibilidad y Calidad de los Datos***

El principal reto que enfrenta la implementación de machine learning en la minería es la calidad y disponibilidad de los datos. Los modelos de machine learning requieren grandes volúmenes de datos de alta calidad para ser entrenados de manera efectiva. Sin embargo, muchas minas, especialmente las más antiguas o aquellas que operan en regiones con infraestructura tecnológica limitada, pueden carecer de datos suficientes o de los sistemas adecuados para

recopilar la información necesaria de manera continua y precisa (Jurdziński, Stefaniuk & Wasilewski, 2017).

Adicionalmente, existe la posibilidad de que los datos pueden estar incompletos o presentar inconsistencias, lo que afecta la capacidad del modelo para hacer predicciones precisas. Por esta razón, la limpieza de los datos y la integración de diversas fuentes de información son tareas esenciales para el éxito de cualquier proyecto de machine learning en la minería.

### ***Complejidad Técnica y Costos Iniciales***

El costo inicial y la complejidad técnica son otros desafíos significativos. Implementar sistemas de machine learning en la minería requiere inversiones importantes en infraestructura tecnológica, desde la instalación de sensores y dispositivos en las minas hasta la adquisición de potentes sistemas de procesamiento de datos. Además, se requiere personal especializado en ciencia de datos y machine learning para diseñar, entrenar y mantener estos modelos, lo que puede ser costoso y difícil de encontrar en muchas regiones mineras.

Además, la implementación de machine learning no siempre ofrece beneficios inmediatos. Puede llevar tiempo recopilar suficientes datos y entrenar un modelo lo suficientemente robusto como para generar predicciones confiables. Este periodo de ajuste inicial puede ser un reto para muchas compañías que buscan ver retornos rápidos en sus inversiones tecnológicas (Hastie, Tibshirani & Friedman, 2009).

### ***Problemas Éticos y Seguridad de los Datos***

El uso extensivo de datos en sistemas de machine learning plantea importantes cuestiones éticas y de seguridad. En la minería, los sistemas recopilan una gran cantidad de información sobre las condiciones de trabajo, el comportamiento de los trabajadores y los patrones de incidentes. Esta recopilación masiva de datos puede generar preocupaciones sobre la privacidad

y el uso adecuado de la información. Es importante que las empresas implementen políticas claras para garantizar que los datos se utilicen de manera ética y que los trabajadores estén informados sobre cómo se procesan sus datos (Mittelstadt et al., 2016).

Además, las minas que implementen modelos de machine learning deben estar preparadas para enfrentar amenazas cibernéticas. Los sistemas que dependen de datos en tiempo real y de modelos automatizados pueden ser vulnerables a ataques cibernéticos, lo que podría comprometer la seguridad de la mina y la integridad de los datos. Por lo tanto, es crucial implementar medidas de ciberseguridad sólidas para proteger tanto la infraestructura física como los sistemas de información.

### ***Adaptabilidad y Escalabilidad***

Uno de los desafíos clave en el uso de machine learning en la minería es la adaptabilidad de los modelos. Las minas son entornos dinámicos y en constante cambio, donde las condiciones pueden variar rápidamente debido a una serie de factores, como la actividad geológica, el uso de equipos pesados o incluso el clima. Los modelos de machine learning deben ser lo suficientemente flexibles como para ajustarse a estos cambios y seguir proporcionando predicciones precisas en todo momento (Anani et al., 2024). Modelos como las redes neuronales pueden ajustarse fácilmente a diferentes tipos de datos, permitiendo su aplicación tanto en minas de carbón como en otros tipos de operaciones mineras (Molina et al., 2023).

### ***Superación de Limitaciones Tradicionales***

Las soluciones tradicionales de seguridad minera, como las inspecciones manuales y los controles periódicos, a menudo no pueden ofrecer una visión en tiempo real del estado de la mina. La minería es una industria tradicional, y muchos trabajadores y gerentes pueden mostrarse escépticos ante la implementación de nuevas tecnologías, especialmente cuando estas

implican cambios significativos en los procedimientos laborales y en la forma en que se supervisan las operaciones.

Para superar esta resistencia, es necesario implementar programas de capacitación extensiva que permitan a los trabajadores comprender y confiar en los nuevos sistemas. Además, la adopción de machine learning debe ir acompañada de cambios organizacionales que fomenten una cultura de innovación y mejora continua. Este enfoque facilitará la aceptación de la tecnología y su uso efectivo en el día a día de las operaciones mineras (Bishop, 2006).

## Conclusiones

La implementación de modelos de machine learning en la minería subterránea de carbón ha demostrado ser una herramienta eficaz para prevenir accidentes y mejorar la seguridad de los trabajadores. Los casos analizados evidencian cómo los algoritmos permiten detectar riesgos de manera oportuna, optimizar procesos y monitorear condiciones críticas en tiempo real.

Los modelos predictivos, como redes neuronales y algoritmos de clasificación, han mostrado una alta precisión en la detección de condiciones peligrosas, como acumulaciones de gases tóxicos y riesgos de colapso de túneles. Esto ayuda a reducir significativamente la ocurrencia de accidentes y permitido implementar medidas preventivas más efectivas.

Aunque los beneficios son evidentes, la adopción de machine learning enfrenta desafíos significativos, como la calidad y disponibilidad de datos, la complejidad técnica y los costos iniciales. Estos factores limitan su implementación en minas con infraestructura tecnológica limitada.

Si bien, la implementación de modelos de machine learning requiere una inversión inicial significativa, los beneficios a largo plazo, como la reducción de accidentes, la optimización de recursos y la disminución del tiempo de inactividad, superan ampliamente los costos, mejorando la rentabilidad de las operaciones.

El uso de machine learning impulsa la innovación en la industria minera, promoviendo la transformación digital y la adopción de tecnologías de vanguardia. Esto posiciona a las empresas que implementan estas soluciones como líderes en sostenibilidad y seguridad.

## **Recomendaciones**

Es esencial invertir en sistemas de monitoreo robustos que permitan la recopilación continua y precisa de datos relevantes para entrenar modelos de machine learning. Esto incluye la instalación de sensores avanzados y la integración de plataformas de análisis en tiempo real.

Promover programas de formación para los trabajadores y equipos de gestión en el uso e interpretación de modelos de machine learning. Esto facilitará la adopción de estas tecnologías y mejorará la confianza en sus predicciones.

Iniciar con proyectos piloto que evalúen la efectividad de los modelos en entornos controlados antes de su implementación masiva. Esto permitirá identificar y mitigar posibles limitaciones técnicas o logísticas.

Establecer alianzas entre instituciones académicas, empresas tecnológicas y operadores mineros para desarrollar soluciones personalizadas que respondan a las necesidades específicas de cada mina.

Diseñar políticas claras para el uso responsable de los datos recopilados, garantizando la privacidad de los trabajadores y la protección contra ciberamenazas.

## Bibliografía

- Agencia Nacional de Minería. (2021). *Guía para el diseño de un plan de prevención y mitigación de explosiones por metano y polvo de carbón en las minas subterráneas de Colombia*. [https://www.anm.gov.co/sites/default/files/guia\\_preencion\\_mitigacion.pdf](https://www.anm.gov.co/sites/default/files/guia_preencion_mitigacion.pdf)
- Alvarez, L., Rodríguez, A., & Ruiz, J. (2020). *Environmental impact assessment using machine learning techniques: Applications in mining*. *Environmental Science and Technology*, 54(12), 7357-7366.
- Anani, A., Adewuyi, S. O., Risso, N., & Nyaaba, W. (2024). *Advancements in machine learning techniques for coal and gas outburst prediction in underground mines*. *International Journal of Coal Geology*, 285, 104471. <https://doi.org/10.1016/j.coal.2024.104471>
- Barreto Caldón, J. A. (2024). *Accidentalidad minera en Colombia: Perspectiva analítica de la problemática de los riesgos mineros por explosiones de gas metano* (Tesis de maestría, Universidad Nacional Abierta y a Distancia UNAD, Facultad de Ciencias Jurídicas y Políticas, Maestría en Gobierno, Políticas Públicas y Desarrollo Territorial).
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Fa, Z., Yan, K., Qiu, Z., Zhang, Y., Liu, Q., & Li, X. (2024). *Who are root hazards? A research on optimization of safety training management in coal mine enterprises from data-driven perspective*. *Resources Policy*, 91, 104891. <https://doi.org/10.1016/j.resourpol.2024.104891>
- Fandango, A. (2018). *Python Data Analysis* (2nd ed., pp. 232-233). Packt Publishing.
- Fawcett, T. (2006). *An introduction to ROC analysis*. *Pattern Recognition Letters*, 27(8), 861-874.

- García, S., Luengo, J., & Herrera, F. (2015). *Data preprocessing in data mining*. Springer.  
<https://doi.org/10.1007/978-3-319-10247-4>
- Gobierno de Colombia. (2015). *Decreto No. 1886: Por el cual se establece el Reglamento de Seguridad en las Labores Mineras Subterráneas*. Diario Oficial, 49.616.  
<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=65325>
- Gong, Y., El-Monier, I., & Mehana, M. (2024). *Machine Learning and Data Fusion Approach for Elastic Rock Properties Estimation and Fracturability Evaluation*. Energy and AI, 16, 100335. <https://doi.org/10.1016/j.egyai.2024.100335>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction (2nd ed.)*. Springer. <https://doi.org/10.1007/978-0-387-84858-7>  
<https://doi.org/10.1007/978-0-387-84858-7>
- ICONTEC - Instituto Colombiano de Normas Técnicas y Certificación. (2015). *Guía para la identificación de los peligros y la valoración de los riesgos en seguridad y salud ocupacional – GTC 45*.  
<https://idrd.gov.co/sitio/idrd/sites/default/files/imagenes/gtc450.pd>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R*. Springer.
- Jordan, M. I., & Mitchell, T. M. (2015). *Machine learning: Trends, perspectives, and prospects*. Science, 349(6245), 255-260.
- Jurdziński, M., Stefaniuk, D., & Wasilewski, M. (2017). *Challenges in data collection for machine learning in mining industry*. In Proceedings of the 24th International Symposium on Mine Planning & Equipment Selection (pp. 423-433). Springer.  
<https://doi.org/10.1007/978-3-319-99220-4>

- Kane, F. (2017). *Hands-On Data Science and Python Machine Learning*. Packt Publishing. (pp. 174-181).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. *Nature*, 521(7553), 436-444.
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). *The ethics of algorithms: Mapping the debate*. *Big Data & Society*, 3(2).  
<https://doi.org/10.1177/2053951716679679>
- Ng, K. M., & Mishra, P. (2018). *Predictive maintenance using machine learning in mining industry*. *Journal of Mining and Mechanical Engineering*, 50(1), 112-118.
- Liu, Z., Gilbert, G., Cepeda, J. M., Lysdahl, A. O. K., Piciullo, L., Hefre, H., & Lacasse, S. (2021). *Modelling of shallow landslides with machine learning algorithms*. *Geoscience Frontiers*, 12(1), 385–393. <https://doi.org/10.1016/j.gsf.2020.04.014>
- Miao, D., Wang, W., Lv, Y., Liu, L., Yao, K., & Sui, X. (2023). *Research on the classification and control of human factor characteristics of coal mine accidents based on K-Means clustering analysis*. *International Journal of Industrial Ergonomics*, 97, 103481.  
<https://doi.org/10.1016/j.ergon.2023.103481>
- Molina, J. M., Vallejo, L. F., López, S., Ortiz, A. F., Soto, D. A., Torero, J., & Molina, A. (2023). *IA y nuevas tecnologías aplicadas a la seguridad minera*. *Protección & Seguridad*. <https://ccs.org.co/wp-content/uploads/2024/01/IA-y-seguridad-minera-PS-411.pdf>
- Samanta, B., Bandopadhyay, A., & Ganguli, R. (2016). *Data mining techniques and applications in mining engineering*. *Journal of the Southern African Institute of Mining and Metallurgy*, 116(12), 1041-1046.

- Santa, N., Keles, C., Saylor, J. R., & Sarver, E. (2021). *Demonstration of Optical Microscopy and Image Processing to Classify Respirable Coal Mine Dust Particles*. *Minerals*, 11(8), 838. Recuperado de <https://doi.org/10.3390/min11080838>
- Qiao, W., & Chen, X. (2022). *Connotation, characteristics and framework of coal mine safety big data*. *Heliyon*, 8(11), e11834. <https://doi.org/10.1016/j.heliyon.2022.e11834>
- Ray, K., Gupta, T., & Sarkar, F. (2023). *Sensitivity analysis and prediction of diesel particulate matter emissions in Indian underground metalliferous mines using regression and machine learning algorithms*. *Measurement*, 213, 112742. <https://doi.org/10.3390/min11080838>
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). *"Why Should I Trust You?": Explaining the predictions of any classifier*. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135-1144. <https://doi.org/10.1145/2939672.2939778>
- Wiens, T., & Islam, Md. S. (2021). *Using acoustic impacts and machine learning for safety classification of mine roofs*. *International Journal of Rock Mechanics and Mining Sciences*, 147, 104912. <https://doi.org/10.1016/j.ijrmms.2021.104912>
- Xuecai, X., Gui, F., Shifei, S., Xueming, S., Jing, L., Lida, H., & Na, W. (2024). *Accident case data-accident causation model driven safety training method: Targeted safety training empowered by historical accident data in coal industry*. *Process Safety and Environmental Protection*, 182, 1208–1226. <https://doi.org/10.1016/j.psep.2023.12.042>
- Yang, K., Zou, Q., Yu, Y., & Xu, H. (2018). *Real-time location systems in underground mines: A review*. *International Journal of Mining Science and Technology*, 28(1), 33-40.

- Yang, Y., Zhou, W., Wang, Z., Jiskani, I. M., & Yang, Y. (2024). *Accurate long-term dust concentration prediction in open-pit mines: A novel machine learning approach integrating meteorological conditions and mine production intensity*. *Journal of Cleaner Production*, 436, 140411. <https://doi.org/10.1016/j.jclepro.2023.140411>
- You, M., Li, S., Li, D., & Xu, S. (2021). *Applications of artificial intelligence for coal mine gas risk assessment*. *Safety Science*, 143, 105420. <https://doi.org/10.1016/j.ssci.2021.105420>
- Zhu, X., & Wu, X. (2004). *Class noise vs. attribute noise: A quantitative study*. *Artificial Intelligence Review*, 22(3), 177-210.