



MODELOS MACHINE LEARNING EN GEOMECAÍNICA MINERA PARA EL CONTROL EFICAZ DE PERFORACIÓN

MACHINE LEARNING MODELS IN MINING GEOMECHANICS FOR THE EFFICIENT CONTROL OF DRILLING

Hitler Juan Poma Cruz¹, Esteban Marín Paucara², Virginia Cervantes Quispe³

*¹Unidad Minera San Rafael, Antauta, Melgar, Puno, Perú

RESUMEN

El estudio se ha realizado en la Unidad Minera San Rafael, distrito Antauta, provincia Melgar, donde se identificó el problema para el modelo adecuado de *machine learning* en geomecánica minera para el control eficaz de perforación y voladura en labores de avance, siendo el objetivo principal evaluar los modelos *machine learning* en geomecánica minera para el control eficaz de perforación y voladura en labores de avance. Los datos de operación referidos a malla y longitud de perforación, tipo de agentes de voladura, tipo y sección de la labor, tipo de roca, mineral y desmonte, número de taladros, avance esperado, avance logrado, estructura, tipo de perforación, equipo y operador, todos estos datos se registraron en formato de reporte, consolidados ellas en una hoja de cálculo y exportados a programación lineal R, las muestras sirvieron para elaborar diferentes modelos, para ser analizados, evaluados y determinados los factores más importantes en el control de avance lineal de las labores de exploración, desarrollo y preparación, el estudio es de tipo descriptivo correlacional y diseño no experimental longitudinal, con los cuales se ha obtenido como resultado que nos permite identificar el objetivo que es el modelo de aprendizaje supervisado que es aplicable y aceptable, cuya conclusión es el uso de modelos de *machine learning* en el contexto es factible desde un punto de vista computacional, sin embargo, se requiere un fuerte trabajo adicional en la curatoría de datos.

Palabras clave: Avance por disparo, longitud de taladro, *machine learning*, minería subterránea, perforación, voladura.

ABSTRACT

The study was conducted at the San Rafael Mining Unit, Antauta district, Melgar province, where the problem was identified for the appropriate machine learning model in mining geomechanics for the effective control of drilling and blasting in advance workings, being the main objective to evaluate the machine learning models in mining geomechanics for the effective control of drilling and blasting in advance workings. The operation data referred to drill mesh and length, type of blasting agents, type and section of the work, type of rock, mineral and waste rock, number of drill holes, expected advance, achieved advance, structure, type of drilling, equipment and operator, all these data were recorded in report format, consolidated in a spreadsheet and exported to R linear programming, the samples were used to develop different models to be analyzed, evaluated and determined the most important factors in the linear advance control of exploration, development and preparation works, the study is descriptive correlational type and longitudinal non-experimental design, with which we have obtained as a result that allows us to identify the objective which is the supervised learning model that is applicable and acceptable, whose conclusion is the use of machine learning models in the context is feasible from a computational point of view, however, a strong additional work in data curation is required.

Keywords: Advance per shot, drill length, machine learning, underground, mining, drilling, blasting.

*Autor para correspondencia: juancito2885@hotmail.com

ORCID: [0000-0002-7030-4574](https://orcid.org/0000-0002-7030-4574)



INTRODUCCIÓN

En la Unidad Minera San Rafael se identificó el problema con la finalidad de encontrar el modelo adecuado de *machine learning* en geomecánica minera para el control eficaz de perforación y voladura en labores de avance para que concentre sus esfuerzos en detallar con la particularidad del uso de las herramientas de *machine learning* con lo que se entendió los factores determinantes del proceso de perforación y voladura en las labores de avance, con lo que se apuntó la obtención del mejor modelo posible para ver qué tan factible tenga un ajuste de calidad para el control eficaz del fenómeno, por lo que se tiene estudios anteriores, así por ejemplo; (Jung y Choi 2021) demostraron que, los estudios de *machine learning* se han llevado a cabo activamente en la industria minera desde 2018, principalmente para la exploración de minerales, versa también la tecnología minera inteligente es la introducción de tecnología de la información y la comunicación de vanguardia, como el Internet de las cosas (IoT), los grandes datos, los móviles, la inteligencia artificial (IA), la realidad aumentada y la realidad virtual, en el ámbito del desarrollo de los recursos minerales; mientras que (Agnieszka *et al.* 2020) indica que, el desarrollo de la tecnología en el proceso minero es tan intensivo, que da lugar a una elevada escala de producción, genera muchos riesgos relacionados tanto con las operaciones y los recursos utilizados, así como también con la interacción entre el sistema minero y el medio ambiente, por otra parte tradicionalmente (Sahu 2018) la industria minera ha tenido dificultades para crear valor a partir del software de optimización y modelización debido a la naturaleza siempre cambiante de la industria, así mismo (Kumar y Kumar 2016) muestra que *machine learning* ofrece una buena manera de anticipar los cambios en la industria minera, como en cualquier otra industria manufacturera, ya que utiliza maquinaria sofisticada y productiva junto con la digitalización, para poder aumentar la productividad y disminuyendo los costos; sin embargo, debido a limitaciones de espacio operativo en minería subterránea (Song *et al.* 2013) considera una interesante línea de investigación futura, exponiendo los métodos de *machine learning* para el procesamiento de datos que están cobrando

impulso en muchos sectores de las geociencias, así mismos donde se incluye en la industria minera; donde el *machine learning* se aplica principalmente a vehículos de conducción autónoma, como los camiones de transporte, delineación de yacimientos y recursos evidenciado ser una técnica efectiva y precisa en los últimos años y se han utilizado con éxito los algoritmos de aprendizaje automático, donde el diagnóstico del análisis computarizado ha atraído a muchos investigadores, lo que ha llevado el accionamiento de algoritmos de aprendizaje automático para el control eficaz, destacándose la importancia del aprendizaje automático en el análisis del modelo basado en computadora, donde el objetivo del *machine learning* es crear un modelo que nos permita resolver una tarea o una actividad en el aprendizaje supervisado, los algoritmos funcionan con datos catalogados intentado descubrir una función que, dadas las variables de entrada, les asigne la etiqueta de salida apropiada (Palaniappan *et al.* 2013); por otro lado (Simeone 2018) indica que el aprendizaje no supervisado tiene lugar cuando no se dispone de datos catalogados para el entrenamiento, en comparación, con el aprendizaje no supervisado, el algoritmo *machine learning* no recibe instrucciones claras sobre qué tipo de respuesta generar; en cambio, tiene la responsabilidad de determinar si hay patrones latentes en los datos; siendo estos procesos de aprendizaje supervisado y no supervisado se pueden combinar con el proceso denominado “aprendizaje semisupervisado” (Handelma *et al.* 2019), mientras los métodos de conjunto es combinar las predicciones de varios estimadores de base construidos con un algoritmo de aprendizaje dado para mejorar la generalizabilidad/robustez sobre un solo estimador (Dietterich 2000); la tarea importante en la actividad de *machine learning* es la clasificación, reconocimiento, donde uno intenta construir algoritmos capaces de construir automáticamente métodos para distinguir entre diferentes ejemplares de gran posibilidad para mejorar y discernir los resultados (Locatello *et al.* 2019); así mismo pueden ser una ayuda valiosa para los operadores mineros en el proceso de toma de decisiones estratégicas, cuyo futuros estudios deben encontrar los

obstáculos asociados, validación e implementación de modelos de *machine learning* en la atención de los controles, así como las implicaciones en perforación y voladura (Mosavi *et al.* 2019); entonces, *machine learning* se define como el estudio de algoritmos informáticos que mejoran automáticamente con la experiencia de las actividades, detectando automáticamente patrones en los datos y usa los patrones descubiertos para predecir datos futuros y otros tipos de toma de decisiones bajo incertidumbre (Calvo 2016), por ende este último tiene orígenes de ingeniería, *machine learning* creció en la informática, sin embargo, ambos tienen un sentido experimental; en base a este estudio (Revuelta 2018) indica que, podemos decir que una de las ventajas de *machine learning* es la personalización de técnicas basadas en la información recibida en tiempo real, además, es lógico porque la aplicación juega un papel importante en el aumento de los rendimientos y los desarrollos recientes en la tecnología minera actual han establecido las operaciones mineras en temas de recopilación y el almacenamiento de una gran cantidad de datos en tiempo real (Isheyskiy y Sanchidrián 2020); así mismo en la investigación, analizamos la cantidad de perforación y voladura de rocas aplicando las técnicas de *machine learning* para el control eficaz en labores de avance y las técnicas de *machine learning* tienen la posibilidad de pronosticar la predisposición con las herramientas geoestadísticas en un conjunto de datos que están disponibles en las labores mineras con la posibilidad de dar un sobre aviso de áreas problemáticas, siempre que la interpolación esté validada con respecto a la base de datos (Malhotra 2015) (Fernandez *et al.* 2022). Gracias al tremendo impulso de la tecnología en área de datos, el aprendizaje está evolucionando, “*Machine learning* se refiere al proceso por el cual la computadora desarrolla el reconocimiento de patrones o capacidad de aprender y hacer continuamente la predicción basada en datos, entonces hacer ajustes sin ser programado específicamente para esto como un medio de inteligencia artificial, el proceso de creación de modelos analíticos permite a las máquinas adaptarse a las nuevas situaciones de independencia (Martinez *et al.* 2022); donde el trabajo de campo es una actividad esencial que debe ser

fundamental en esta etapa siendo la recopilación de datos debe ser representativa, dependiendo de qué tan seguro y confiable se quiera trabajar (Moyano 2022); entonces los modelos geomecánicos con condiciones in-situ brindan información sobre el plan de producción más adecuado, así como la compactación de la roca y efectos de tensión-deformación y la aplicación de la simulación geomecánica está llegando al trabajo propio, por lo tanto se determinará el impacto de la geomorfología en la productividad de las labores horizontales formado por matriz rocosa y por discontinuidades, con un carácter heterogéneo, comportamiento discontinuo y normalmente anisótropo (Pachón *et al.* 2015) (Montaño *et al.* 2021); sin embargo el resultado es evidente y en este tipo de afirmaciones no tienen ninguna base geomecánica aceptable desde el punto de vista ingenieril para caracterizar un bloque de roca donde se pretende excavar (Cuervas *et al.* 2015); así mismo es necesario conocer los parámetros básicos de la roca y las discontinuidades, así como la estructura del bloque, incluyendo aspectos como el número de familias de piedras, discontinuidades, media distancias de discontinuidades planas y propiedades geomecánicas básicas de las discontinuidades (Correa *et al.* 2021); por otra parte (Zhang *et al.* 2019) muestra la clasificación de macizo rocoso en ingeniería que intenta tener en cuenta los aspectos geológicos más importantes que afectan al macizo rocoso para evaluar la calidad que forma la columna vertebral del enfoque de diseño empírico y ampliamente adoptado en la ingeniería de rocas; luego (Sun *et al.* 2019) determina que, el mapeo de prospectividad mineral basado en SIG se está aplicando cada vez más para minimizar el riesgo en la exploración minera, y (Ortega *et al.* 2016) (Sabah *et al.* 2019) indican que, el diseño de la malla de perforación se realizó con base a los cálculos de los parámetros geomecánicos del macizo rocoso con la predicción de la velocidad de penetración de la perforación (ROP) es un enfoque para optimizar su rendimiento de perforación y voladura que permiten no sólo romper las rocas de una parte frontal de una excavación, sino también provocar un efecto interno, que puede conducir a daños no deseados que, a su vez conllevan, un aumento de los gastos de las operaciones de excavación y problemas de

seguridad para el personal (Kirsanov *et al.* 2016), entonces (Hergenrether 2017) indica que la aplicación de los métodos de cálculos numéricos actuales propicia un reajuste indispensable de los diseños de sostenimiento, permitiendo verificar y controlar los factores que intervienen en la estabilidad de una excavación y que estará fuertemente condicionado por el nivel de conocimiento y capacidad de estudio de los factores geológicos; y con las propiedades de las rocas, las características mecánico-estructurales del macizo, las propiedades de las sustancias explosivas y la acción de la explosión sobre el medio, se elaboró la metodología para el diseño de voladuras de contorno en el laboreo de excavaciones subterráneas horizontales (Diéguez 2014), por otra parte (Sandvik 2020) versa que la perforación está compuesta por un conjunto de martillos perforadores montados sobre brazos articulados de accionamiento hidráulico para la ejecución de los trabajos de perforación en los frentes de avance; así la resistencia de la roca tiene una fuerte influencia en la deflexión de los taladros perforados en roca blanda que ocurren a un ritmo más alto, donde la flexión de la barra provoca un aumento en la fricción entre la barra, la broca y la pared del taladro perforado, lo que hace que se expanda el diámetro a ser cargado con explosivo (Rincón & Molina 2017), y cuando la roca recibe el estado tensional proporcionado por la explosión, tiende a romperse debido al corte, y el confinamiento dificulta a que el cizallamiento sea difícil en las voladuras subterráneas enfatizando aún más este confinamiento, por lo que es importante tenerlo en cuenta a la hora de diseñar la construcción de una labor de avance (Correa & Rueda 2021).

El objetivo fue evaluar los modelos de *machine learning* en geomecánica minera para el control eficaz de perforación y voladura en labores de avance – Unidad Minera San Rafael. Así mismo se propuso objetivos específicos como analizar los modelos de *machine learning* en geomecánica minera adecuados en perforación y voladura en labores de avance en la Unidad Minera San Rafael y determinar el control eficaz de perforación y voladura en labores de avance en la Unidad Minera San Rafael.

METODOLOGÍA

Ámbito de estudio

La investigación se realizó en la Unidad Minera San Rafael, ubicado en el distrito de Antauta, provincia de Melgar, departamento de Puno y que se encuentra a 4523 m.s.n.m. en las coordenadas geográficas UTM latitud sur 14°13'58"S, -14,2327292N y latitud oeste 70°19'15"O, -70,3207397N.

Descripción de métodos

Se ha considerado la descripción de los métodos para cada objetivo específico que es como sigue:

- a) El periodo de estudio fue de 24 meses desde enero del 2000 hasta diciembre del 2021 por que la investigación presenta un enfoque de tipo cuantitativo y diseño no experimental longitudinal ya que se realizó la descripción de algoritmos matemáticos para conocer el modelo adecuado de *machine learning* en geomecánica minera para el control eficaz de perforación y voladura en labores de avance, la población estuvo conformado por 3 500 disparos y el muestreo fue la misma cantidad que la población por pertenecer a una población de datos.
- b) Se descripción en forma detallada los materiales, los insumos y los instrumentos utilizados que a continuación se muestran: El material para la investigación refiere, a que la tecnología minera inteligente es la introducción de tecnología de la información y la comunicación de vanguardia, como el Internet de las cosas (IoT), los grandes datos, los móviles, la inteligencia artificial (IA), la realidad aumentada y la realidad virtual (Jung & Choi 2021) para encontrar el modelo adecuado utilizando equipo de perforación Jumbo electrohidráulico Sandvick DD311 compacto y versatil para perforación frontal (Sandvik 2020) y cargador de ANFO neumático de 150 lt accionado por 90-100 psi de aire comprimido (Castem 2022).

Para la recolección de la información se utilizó la técnica observacional generando una base de datos en Excel, que contiene datos como; fecha, semana, zona, nivel, labor, estructura, sección, fase, tipo de perforación, equipo, año de adquisición,

avance esperado, avance topográfico, tipo de disparo, tipo de roca, número de taladros, explosivo, tipo de labor, material, longitud de perforación y eficiencia de perforación para efectuar la curatoría y encontrar el modelo adecuado de *machine learning* en geomecánica, es por esta razón que un requerimiento para introducirse en este campo es poseer conocimientos de conceptos de estadística (Fernandez *et al.* 2022).

En tanto los instrumentos que se aplicó (Ortega *et al.* 2016) para el resultado del diseño de la malla de perforación y voladura es el uso de la estación total Leica TS07 R500 de 5" y distanciómetro laser Leica "Disto D2" (Leica 2021) las cuales facilita las mediciones más precisas después de la voladura en labores subterráneas durante su ejecución demostrando los datos de avance topográfico.

- c) Se han analizado las variables como son:
El modelo adecuado de *machine learning* en geomecánica minera: Se define tradicionalmente que (Sahu 2018) la industria minera ha tenido dificultades para crear valor a partir del software de optimización y modelización debido a la naturaleza siempre cambiante de la industria. Machine learning ofrece una buena manera de anticipar esos cambios, (Kumar & Kumar 2016) ya que utiliza maquinaria sofisticada y productiva, junto con la digitalización, para poder prosperar aumentando la productividad y disminuyendo los costos.
El control eficaz de perforación y voladura en labores de avance: La velocidad de penetración de la perforación (ROP) es un enfoque para optimizar el rendimiento de la perforación (Kirsanov *et al.* 2016) y voladura que permiten no sólo romper las rocas de una parte frontal de una excavación con las (Diéguez 2014) propiedades de las rocas, las características mecánico-estructurales del macizo, las propiedades de las sustancias explosivas y la acción de la explosión sobre el medio, se elaboró la metodología para el diseño de voladuras de contorno en el laboreo de excavaciones subterráneas horizontales.
- d) La prueba estadística que se aplicó fue el lenguaje de programación R que se utiliza principalmente para el análisis y el trazado

de datos estadísticos (R Core Team 2019). En esta investigación, analizamos la cantidad de perforación y voladura de rocas aplicando las técnicas de machine learning que tienen la posibilidad de pronosticar la predisposición (Malhotra 2015) con las herramientas geoestadísticas en un conjunto de datos que están disponibles en las labores mineras con la posibilidad de dar un sobre aviso de áreas problemáticas (Fernandez *et al.* 2022).

RESULTADOS Y DISCUSIÓN

En esta base de datos, la una única tabla donde cada columna corresponde a una pregunta y cada fila a una observación, esta variable se categoriza posteriormente utilizando un porcentaje por sobre y bajo el avance esperado (Bajo $\leq 0,96$, Alto $\geq 1,04$, Normal el resto). Por lo tanto, se utiliza un algoritmo llamado SMOTE que genera observaciones en los factores artificiales para generar clases balanceadas. Un típico *script* de R comienza con una serie de declaraciones de paquetes que podrían ser utilizados posteriormente.

```

Datos <- read.csv(file = 'Base_de_datos_R_Juan_Poma_Cruz.csv')
drop <- c("?..Fecha", "Semana", "Labor", "MES", "Tipo_Perforacion",
"Tipo.de.Disparo", "Operador", "AGNO", "Nivel", "Avance.top.",
"PorcEffPerf.", "Estructura", "Equipo")
df = Datos[, !(names(Datos) %in% drop)]
# Declaraciones de variables categoricas
df$Zona <- as.factor(df$Zona)
df$Seccion <- as.factor(df$Seccion)
df$Fase <- as.factor(df$Fase)
df$Tipo.de.roca <- as.factor(df$Tipo.de.roca)
df$EXPLOSIVO <- as.factor(df$EXPLOSIVO)
df$TIPO.DE.LABOR <- as.factor(df$TIPO.DE.LABOR)
df$MATERIAL <- as.factor(df$MATERIAL)
df$Agno.de.adq <- as.factor(df$Agno.de.adq)
df$Clasificacion <- as.factor(df$Clasificacion)
df$Avance.Esp. <- as.factor(df$Avance.Esp.)
df$NTaladros <- as.factor(df$NTaladros)

```

Figura 1: Identificación de categorías

(Agnieszka *et al.* 2020) como también (Jung & Choi 2021) realizaron estudios utilizando modelos de aprendizaje profundo referente al sistema minero y medio ambiental, aplicando los modelos *machine learning* para las operaciones mineras, específicamente en las labores de Exploración, Desarrollo y Preparación, principalmente para determinar la realidad virtual en el ámbito del desarrollo de las operaciones en labores horizontales e inclinadas, para la demostración de los resultados con los datos se ha llevado a cabo el uso de la tecnología de la información específicamente con los datos obtenidos en campo en la etapa de los procesos operacionales, mientras que (Isheyskiy & Sanchidrián 2020) afirman que los desarrollos recientes en la tecnología de minería actual han establecido las operaciones mineras en temas de recopilación y el almacenamiento de una gran

cantidad de datos en tiempo real. El propósito del *machine learning* es crear un modelo que nos permita resolver una tarea o una actividad específica en la industria minera con el aprendizaje supervisado, los algoritmos funcionan con datos catalogados, intentado descubrir una función que, dadas las variables de entrada, les asigne la etiqueta de salida apropiada y con el aprendizaje no supervisado tiene lugar cuando no se dispone de datos catalogados para el entrenamiento (Simeone 2018).

Muestra de datos para entrenamiento

Se deben especificar los conjuntos de entrenamiento y de test para el modelo, se deben eliminar algunos atributos puesto que ellos han demostrado no ser útiles en la caracterización de la variable de respuesta después de un cierto número de pruebas preliminares, puesto que primero debemos anotar los nombres de los

atributos que no se considerarán en el proceso de ajuste y a continuación se utiliza la sintaxis de R para eliminar los mismos del *dataframe* del archivo de la base de datos en Excel, las cuales serán variables que no tienen de mucha relevancia para el análisis de las categorías que

son directamente los factores. El conjunto de entrenamiento son el subconjunto de los registros utilizados para ajustar (entrenar) el modelo porcentual del conjunto de entrenamiento (Figura 2).

```
smod <- df

# Generar muestra de datos para entrenar, selección de 70% de filas
alpha <- 0.7 # Porcentaje del conjunto de entrenamiento
inTrain <- sample(1:nrow(smod), alpha * nrow(smod))

# Definir conjuntos de entrenamiento y test
entrenamiento <- smod[inTrain,]
prueba <- smod[-inTrain,]
```

Figura 2: Muestra de datos para entrenamiento

Mientras (Dietterich 2000) los métodos de conjunto es combinar las predicciones de varios estimadores de base construidos con un algoritmo de aprendizaje dado para mejorar la generalizabilidad/robustez sobre un solo estimador. El conjunto de test son el subconjunto de los registros a los cuales se les aplica el modelo ya ajustado para entender la capacidad de generalización del modelo recién ajustado, (Calvo 2016) detectando automáticamente patrones en los datos y usa los patrones descubiertos para predecir datos futuros y otros tipos de toma de decisiones bajo incertidumbre.

Árbol de decisión

Rpart, es un código de el árbol de decisión para determinar la participación ajustado del modelo, donde el árbol se construye utilizando atributos para construir ramas, la idea es construir nodos terminales homogéneos, el modelo ajustado se aplica a los datos de prueba y se generan las salidas del proceso tanto de manera gráfica como de manera tabular, esto quiere decir que se determina la categorización de los datos analizados que son bajo, normal y sobre que significa mejorar los códigos tratados en la ejecución de labores de avance en operaciones mineras (Figura 3).

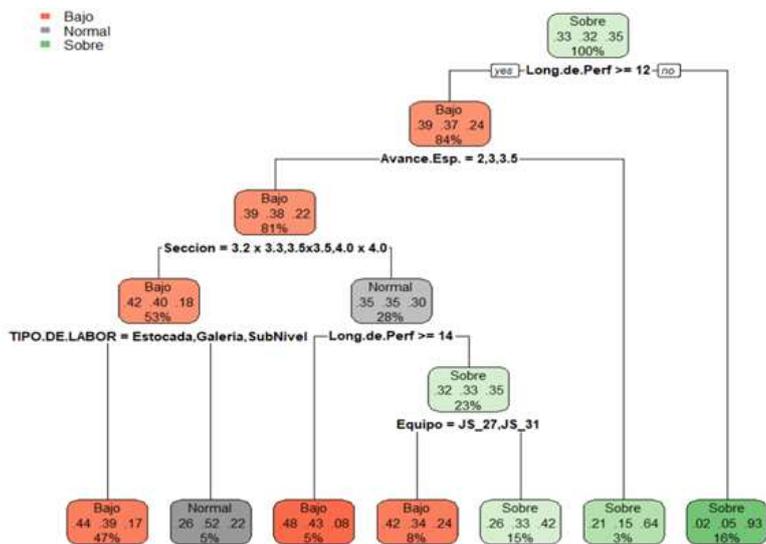


Figura 3: Rpart, árbol de decisión

Estudios directamente realizados en la geomecánica minera, perforación y voladura de labores horizontales e inclinadas (operaciones mineras subterráneas) aplicados con modelos *machine learning* no están siendo desarrollados ya que la tecnología de equipos mineros no está siendo adaptados todavía para tener la capacidad de almacenar información necesaria para poder aplicar en la ciencia de datos, tampoco existe un estricto control de registro de las actividades. (Sun *et al.* 2019) demuestra que la aplicabilidad de los modelos *machine learning* son herramientas eficaces basados en la base de datos para la prospectividad de los minerales relacionados directamente con la geoinformación de distintas fuentes de información aplicado con la finalidad de minimizar el riesgo en la exploración minera. (Sabah *et al.* 2019) demuestra su estudio de la predicción de la velocidad de penetración de la perforación (ROP) con un enfoque de rendimiento con varios algoritmos de aprendizaje automático de una roca con características de estudios geológicos.

Modelo Bagging

La importancia de los variables es el resultado aplicado utilizando el modelo Bagging, donde

nos muestra que para evitar los problemas de sobreajuste y tratar de mejorar la clasificación resultante del modelo se propone el uso de un conjunto de modelos. Se corren varios modelos con distintas muestras y se clasifica en los datos de test de acuerdo a una votación por mayoría si es que se está clasificando o se calcula el promedio si es que es un árbol de regresión. La tecnología minera inteligente produciendo, recopilando y compartiendo la disponibilidad de datos recibidos por los sensores una gran cantidad de información operacional en tiempo real haciendo que los ordenadores y las computadoras desarrollen las técnicas de la inteligencia artificial para la predicción atrayendo la ciencia de datos, La implementación del modelo es similar al árbol de decisión, sin embargo, se tiene una sintaxis distinta para el modelo usado en el ajuste, es decir, los atributos en general que presentan mayor relevancia para determinar la eficiencia del avance son el número de taladros, el tipo de labor y en menor medida el año de adquisición de los equipos. A pesar de esta información, la matriz resultante del proceso de ajuste no resulta ser muy alentadora y el modelo aplicado a los datos de test, exhibe desviaciones importantes respecto a lo considerado ideal, como observamos lo siguiente (Figura 4):

```
> print(VI)
```

	Overall
Agno.de.adq	86,35191
Avance.Esp.	73,80836
EXPLOSIVO	51,37436
Fase	58,04580
Long.de.Perf	57,16227
MATERIAL	40,38530
NTaladros	104,41696
Seccion	71,87813
TIPO.DE.LABOR	105,02059
Tipo.de.roca	59,06214
Zona	43,75629

Figura 4: Importancia de las variables

También estudios realizados en operaciones mineras subterráneas demuestran que no se aplicó de forma determinante para obtener resultados para la mejora de indicadores como (Depaz & Caceres 2018) y (Sahu 2018) además, describen que la industria minera tiene muchas dificultades para crear un valor adicional a partir de la implementación de los softwares de optimización y modelización debido a la

CONCLUSIONES

Como una primera aplicación de este tipo de técnica en la Mina San Rafael, se ha generado conciencia de la importancia de la recolección de datos fiables, oportunos y certeros. Por lo demás, es importante volver a lo fundamental del fenómeno, para considerar de la mejor El uso de modelos de *machine learning* en el contexto del área de estudio es factible desde un punto de vista computacional, sin embargo, se requiere un fuerte trabajo adicional en la curatoría de datos y en la definición más

siempre cambiante de la industria, (Kumar & Kumar 2016) indica que a consecuencia de la utilización de las maquinarias sofisticadas y productivas, junto con la digitalización de los datos, llegando a aumentar la productividad y la disminución de costos con un sinnúmero de técnicas de explotación de yacimientos mineros ya que estos métodos no son universales y la aplicación depende de las características de cada mina.

forma posible, el registro de datos de información vitales en la explicación del fenómeno. Cuando se abordó el problema, se tuvo que armar una base de datos con la poca información existente, lo que a la larga ha sido contribuido negativamente en la ejecución del proyecto.

precisa de los mecanismos fundamentales que definen el avance efectivo: es claro de los experimentos desarrollados que la data es insuficiente en la caracterización del fenómeno, es decir, debe haber datos no

consignados en la base de datos actual que permitirían mejorar el ajuste que se ha obtenido; y se propone que se agreguen otros factores que permitan caracterizar la propagación de la fractura en el macizo rocoso, por ejemplo, la geometría de las perforaciones en el frente si bien esta registrada, adolece de falencias relativas a la carga de explosivos y secuencia de los disparos.

El uso de modelos de *bagging*, identifica al menos variables relevantes para el fenómeno, las que tal vez vale la pena medir de mejor forma o afinar las técnicas de registro de información. El comentario previo, más que ser visto como un problema, debe ser visto como una oportunidad, esto porque al menos ya se ha determinado que en el análisis del fenómeno, no se cuenta actualmente con toda la información que lo determina, por lo tanto, la investigación adicional y recolección adicional de data solo mejorara el modelamiento en curso.

AGRADECIMIENTOS

Un agradecimiento especial a todo los colaboradores y empleados de la empresa especializada AESA-Unidad Minera San Rafael. Por ser parte de este trabajo de investigación.

REFERENCIAS

- Agnieszka, T.; Werbinska-Wojciechowska, S.; Wroblewski, A. 2020. Risk Assessment Methods in Mining Industry. *Revista Applied Sciences*, 01 (15).
<https://doi.org/10.3390/app10155172>
- Calvo, L. 2016. Strategy based on machine learning to deal with untagged data sets using rough sets and/or information gain, 4-15.
<http://dx.doi.org/10.18845/tm.v29i5.2581>
- Castem soporte subterráneo, 2022. Ficha de productos CASTEM.
<https://castem.com.pe/>
- Correa, A. & Rueda, J. 2021. RMR and type of explosive: incidence in underground blasting, 19(1), 41-50, Pamplona-Colombia.
<https://doi.org/10.24054/bistua.v19i1.959>
- Correa, A.; Rueda, J.; Rodríguez, J. 2021. Expresión propuesta para el diseño de voladuras en túneles de carretera, caso colombiano, 19(1), 31-40. Pamplona-Colombia.
<https://doi.org/10.24054/bistua.v19i1.957>
- Cuervas, J.; Bordehore, L.; Nazareno, J.; Escobar, K. 2015. Evaluation of the stability of small diameter mining excavations using geomechanical classifications and empirical analysis: the case of the San Juan mine, Ecuador, 35, 19-28, Guayaquil, Ecuador.
<https://dialnet.unirioja.es/servlet/articulo?codigo=6054936>
- Depaz, L. M., y Caceres, C. M. 2018. Geomecánica aplicada al diseño de malla de perforación de la GA-475e del nivel 2050 en la unidad Alpacay, MY SAC año 2016.
<http://www.repositorio.unasam.edu.pe/handle/UNASAM/2387>
- Diéguez, Y. 2014. Metodología para el diseño de voladuras de contorno en el laboreo de excavaciones subterráneas horizontales.
<http://ninive.ismm.edu.cu/bitstream/handle/123456789/1414/Yoandro.pdf>
- Fernández, J.; Espinoza, A.; Quispe, C.; Asencio, E.; Aponte, R. 2022. Importancia del desarrollo de modelos geomecánicos 3d en entornos geológicos complejos, aplicado a la mina catalina huanca, *Instituto de ingeniero de minas del Perú*.
<https://revistamineria.com.pe/tecnico-cientifico/importancia-del-desarrollo->

- [de-modelos-geomecanicos-3d-en-entornos-geologicos-complejos,-aplicado-a-la-mina-catalina-huanca,aya#:~:text=La%20importancia%20del%20modelo%20geomec%C3%A1nico%20largo%20de%20la%20operaci%C3%B3n](#)
- Handelma, G.S.; Kok, H.K.; Chandra, R.V.; Razavi, A.H.; Huang, S.; Brooks, M.; Lee, M.J.; Asadi, H. Peering 2019. Into the Black Box of Artificial Intelligence: Evaluation Metrics of Machine Learning Methods. *Am. J. Roentgenol.* 212, 38–43. <https://doi.org/10.2214/AJR.18.20224>
- Hergenrether, P. 2017. Consideraciones geomecánicas en el diseño de secciones tipo para un túnel minero. https://digibuo.uniovi.es/dspace/bitstream/handle/10651/43716/TFM_PabloDanielHergenretherPerez.pdf?sequence=6&isAllowed=y
- Isheyskiy, V. & Sanchidrián, J. 2020. Prospects of Applying MWD Technology for Quality Management of Drilling and Blasting Operations at Mining Enterprises, *Minerales*. 10-925. <https://doi:10.3390/min10100925>
- Jung, D., & Choi, Y. 2021. Systematic review of machine learning applications in mining: Exploration, exploitation, and reclamation. *Minerals*, 11(2), 1–20. <https://doi.org/10.3390/min11020148>
- Kirsanov, A.; A Vokhmin, S.; & S Kurchin, G. 2016. A brief history of the development of blasting and the modern theory of rock breaking. *Journal of Degraded and Mining Lands Management*, 3(4), 617–623. <https://doi.org/10.15243/jdmlm.2016.034.617>
- Kumar, D. & Kumar, D. 2016. Rational Implementation of Mining Technology. *Management of Coking Coal Resources*, 113–176. https://www.researchgate.net/publication/301244393_Rational_Implementation_of_Mining_Technology
- Leica Geosystems AG, 2021. Estaciones totales manuales. https://www.instop.es/instop/leica_geosystems.php
- Locatello, F.; Bauer, S.; Lucic, M.; Rätsch, G.; Gelly, S.; Schölkopf, B.; Bachem, O. 2019. Challenging Common Assumptions in the Unsupervised Learning of Disentangled Representations. *Proceedings of the 36th International Conference on Machine Learning*, PMLR 97, 4114–4124. <http://proceedings.mlr.press/v97/locatello19a/locatello19a.pdf>
- Malhotra, R. A. 2015. Systematic review of machine learning techniques for software fault prediction. *Appl. Soft Comput.* 27, 504–518. <http://dx.doi.org/doi:10.1016/j.asoc.2014.11.023>
- Martínez, R.; Parkinson, C.; Caruso, M.; López, D.; Vargas, R.; Rojas, N. 2022. Propuesta de técnicas de validación para la calidad de datos abiertos e identificación de patrones para predicciones con *machine learning*. <http://sedici.unlp.edu.ar/handle/10915/143365>
- Miranda, S. & Ortiz, J. A. 2020. Los paradigmas de la investigación: un acercamiento teórico para reflexionar desde el campo de la investigación educativa. *Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 11(21). <https://doi.org/10.23913/ride.v11i21.717>
- Montaño, J.; Rincón, J.; Vargas, W.; Alvarado, H. 2021. Increased performance of the drilling and blasting system at the El Lucero mining operation. 19(1), 70-74. Pamplona-Colombia. <https://doi.org/10.24054/bistua.v19i1.946>
- Mosavi, A.; Salimi, M.; Ardabili, S.F.; Rabczuk, T.; Shamshirband, S.;

- Varkonyi-Koczy, A.R. 2019, State of the Art of Machine Learning Models in Energy Systems, a Systematic Review. *Energies*, 12, 1301. <https://doi.org/10.3390/en12071301>
- Moyano, C. 2022. *Aproximación metodológica para validar parámetros geomecánicos e hidráulicos en un medio fracturado (caso túnel de La Línea)*, Universidad Nacional de Colombia Facultad de Ingeniería, Departamento de Ingeniería Civil y Agrícola Bogotá, Colombia. <https://repositorioslatinoamericanos.uchile.cl/handle/2250/3409300>
- Ortega, C.; Jaramillo, A.; Molina, J. 2016. Drilling grid blasting upgrading based on Geological Strength Index (GSI), case “La Maruja” mine, Colombia, 40, 32-38, Facultad de Minas, Universidad Nacional de Colombia, Medellín, Colombia. <https://repositorio.unal.edu.co/handle/unal/59224>
- Pachón, Y.; Cardenas, J.; Ortiz, O.; Quintero, Y. 2015. Estimación del potencial de producción de un pozo horizontal posfracturado hidráulicamente en una formación de shale gas con aplicación geomecánica. <https://revistas.uamerica.edu.co/index.php/rinv/article/view/167>
- Palaniappan, R.; Sundaraj, K.; Ahamed, N.U. 2013. Machine learning in lung sound analysis: A systematic review. *Biocybern. Biomed. Eng.* 33, 129–135. <https://doi.org/10.1016/j.bbe.2013.07.001>
- R Core Team 2019. *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing. <https://cran.r-project.org/>
- Revuelta, R. 2018. Aplicación de técnicas de machine learning, un caso práctico. <https://repositorio.unican.es/xmlui/handle/10902/15652>
- Rincón, J. & Molina, J. 2017, Improvement of the breakage through the drilling deviations control, case “El Roble” mine, Colombia, 42, 45-54, Facultad de Minas, Universidad Nacional de Colombia, Medellín, Colombia.
- Sabah, M.; Talebkeikhah, M.; Wood, D. A.; Khosravianian, R.; Anemangely, M.; Younesi, A. 2019. A machine learning approach to predict drilling rate using petrophysical and mud logging data. *Earth Science Informatics*, 12(3), 319–339. <https://link.springer.com/article/10.1007/s12145-019-00381-4>
- Sahu, R. 2018. How harnessing computer vision and machine learning will revolutionize global mining. *Mining Engineering*, June, 33–35. <https://blog.strayos.com/harnessing-computer-vision-and-machine-learning/>
- Sandvik, (2020). *Manual del operario de Jumbo Sandvik*. Manual del operario, SANDVIK. <https://es.scribd.com/document/400212117/Manual-Perforadora-Jumbo-Dd311-Sandvik-pdf#>
- Simeone, O. 2018. A Very Brief Introduction to Machine Learning With Applications to Communication Systems. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8542764>
- Song, Z.; Rinne, M.; Van, A. 2013. A review of real-time optimization in underground mining production. *Journal of the Southern African Institute of Mining and Metallurgy*, 113(12), 889–897. http://www.scielo.org.za/scielo.php?script=sci_arttext&pid=S2225-62532013001200004
- Sun, T.; Chen, F.; Zhong, L.; Liu, W.; Wang, Y. 2019. GIS-based mineral prospectivity mapping using machine learning methods: A case study from Tongling ore district, eastern China. *Ore Geol.*, 109, 26–49.

<https://doi.org/10.1016/j.oregeorev.2019.04.003>

Vemba Mucuta, H.; Cartaya, M.; Cuni, J. 2019. Rock mass geomechanical assessment on exploitation areas of Castellanos polymetallic deposit. *Minería y Geología*. 35(4), 430-440.

http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1993-80122019000400430

Zhang, Q.; Huang, X.; Zhu, H.; Li, J. 2019. Quantitative assessments of the correlations between rock mass rating (RMR) and geological strength index (GSI), 83, 73-81. <https://doi.org/10.1016/j.tust.2018.09.015>