



Universidad Nacional
de Trujillo

Journal of Advanced Mining Modeling (JAMM)

Página web de la revista: <https://revistas.unitru.edu.pe/index.php/jamm/index>
Vol. 2, Nº 1, pp. 24-41, Enero – Junio 2026



Journal of Advanced
Mining Modeling
(JAMM)

Implementación del algoritmo K-Nearest Neighbors para la predicción de desprendimiento de taludes de mina a cielo abierto

Yordan Juver Rodríguez-Alvarez^{1*}

¹. Departamento de Ingeniería de Minas / Facultad de Ingeniería / Universidad Nacional de Trujillo, Trujillo, Perú

* Autor de correspondencia: h203400820@unitru.edu.pe (Y. Rodríguez-Alvarez)

Recibido 13 de diciembre de 2025 Revisado 18 de diciembre de 2025 Aceptado 31 de diciembre de 2025 Publicado en línea 03 de enero de 2026

Resumen

El propósito de este estudio fue analizar el uso del método K-Nearest Neighbors. para anticipar desprendimientos en taludes de minería superficial, mediante el uso de los parámetros de cada talud. El examen de los peligros de deslizamientos en pendientes en una mina a cielo abierto se puede describir como la evaluación del peligro de colapso de estas construcciones, siendo fundamental para asegurar la seguridad. Para lograr esto, es imperativo supervisar estas estructuras y evaluar todas las variables que podrían influir en su estabilidad. Se empleó un enfoque cuantitativo, realizando una evaluación del factor de seguridad estable (ST), medio estable (OF) e inestable (FSB), considerando la distancia de los K=11 vecinos más cercanos, las relaciones geomecánicas de los parámetros ayudo mucho en las predicciones de los taludes si tienen mayor estabilidad, con la implementación del algoritmo se obtuvieron resultados muy eficaces para la predicción de taludes, lo cual se muestran en una clasificación de precisión de 0.90, sensibilidad (recall) 0.90, F1-score 0.90 de estabilidad del talud (ST) y Accuracy (Exactitud): 83.33%.

Finalmente, el método KNN es una alternativa confiable para evaluar las predicciones de condiciones estables de taludes en minería a cielo abierto, lo cual el valor k tiene una eficaz de predicción de 73.73%, ya que facilita la toma de decisiones técnicas y que contribuye en la reducción del riesgo de desprendimientos a partir de un análisis de las variables de talud.

Palabras claves: K-Nearest Neighbors (KNN), Estabilidad de taludes, Minería a cielo abierto, Predicción de desprendimientos, Geotecnia.

Abstract

The purpose of this study was to analyze the use of the K-Nearest Neighbors (KNN) method to anticipate slope failures in open-pit mining, using the geotechnical parameters of each slope. The assessment of landslide hazards in open-pit mine slopes can be described as the evaluation of the potential collapse risk of these structures, which is essential to ensure operational safety. To achieve this, continuous monitoring of the slopes and the evaluation of all variables that may influence their stability are imperative. A quantitative approach was applied, evaluating the factor of safety classified as stable (ST), moderately stable (OF), and unstable (FSB), considering a distance of K = 11 nearest neighbors. The geomechanical relationships among the slope parameters significantly contributed to improving the prediction of slope stability conditions. With the implementation of the KNN algorithm, highly effective results were obtained for slope stability prediction, achieving a precision of 0.90, sensitivity (recall) of 0.90, and F1-score of 0.90 for stable slopes (ST), as well as an overall accuracy of 83.33%. Finally, the KNN method is a reliable alternative for predicting stable slope conditions in open-pit mining. The selected k-value demonstrated a prediction efficiency of 73.73%, facilitating technical decision-making and contributing to the reduction of slope failure risks through a systematic analysis of slope variables.

Keywords: K-Nearest Neighbors (KNN), Slope stability, Open-pit mining, Slope failure prediction, Geotechnics.

1. Introducción

La minería de datos constituye un proceso que emplea diversas herramientas de análisis con el fin de identificar patrones, modelos y relaciones dentro de grandes conjuntos de información, los cuales pueden utilizarse posteriormente para realizar predicciones confiables.

En el ámbito Minero, múltiples disciplinas intervienen para garantizar que las operaciones se desarrollen de forma segura y eficiente. Una de las áreas esenciales es la geotecnia, cuyo propósito es estudiar, interpretar y anticipar el comportamiento de suelos y rocas, de manera que las obras y actividades propias de la minería se ejecuten sin que ocurran deslizamientos o fallas estructurales [1].

Dentro de esta disciplina, la estabilidad de taludes en explotaciones mineras superficiales es un aspecto fundamental, ya que está vinculada al análisis de las características geotécnicas de los materiales que conforman el tajo, considerando sus tres escalas: banco, inter rampa y global. Se considera que un talud presenta falla cuando alcanza un desplazamiento que compromete su seguridad operativa o cuando deja de cumplir adecuadamente la función para la que fue diseñado. En tales situaciones, es necesario modificar la configuración y el diseño inicial establecidos por la ingeniería.

Uno de los algoritmos más utilizados en el campo del aprendizaje automático para la generación de modelos predictivos es el (KNN). Este método aprende identificando las similitudes entre un dato nuevo y otros datos cercanos dentro del espacio multidimensional. El algoritmo KNN forma parte de las técnicas de clasificación que suelen emplearse en procesos de minería de datos [2].

El problema al cual se enfrentan los mineros es la construcción de taludes con una buena estabilidad, lo que motiva la formulación de la siguiente interrogante: ¿De qué manera se aplica el algoritmo (KNN) para predecir el colapso en taludes de minería a cielo abierto?

El objetivo general de este artículo es examinar la aplicación del K-Nearest Neighbor (KNN) para anticipar desprendimiento en taludes de minería superficial. Como objetivos específicos, se plantean: Analizar la relación entre diversas características geotécnicas a través de KNN para anticipar deslizamientos; evaluar la efectividad del modelo KNN utilizando medidas de precisión en la clasificación y la matriz de confusión; analizar cómo se distribuyen los datos en relación al conjunto de datos de entrenamiento y de prueba usando el K-Vecino más cercano para anticipar deslizamientos de taludes.

En este artículo de investigación contribuye al conocimiento sobre la predicción de eventos mineros, específicamente los deslizamientos de taludes, mediante la aplicación de un método algorítmico basado en datos recolectados en campo y procesados utilizando el lenguaje de programación Python.

2. Materiales y Metodología

La presente investigación tiene como propósito demostrar la realidad de la información con el debido rigor científico, lo que permitirá obtener resultados válidos y eficientes mediante la aplicación del algoritmo (KNN) para predicción de colapso de taludes en minería superficial. Las labores mineras requieren desarrollarse sobre la base de estudios geotécnicos del macizo de las rocas, con el fin de determinar el estado de los suelos y rocas. En las operaciones a cielo abierto, conocer las propiedades físicas de las rocas es siempre un requisito esencial[3].

2.1. Partes de un talud

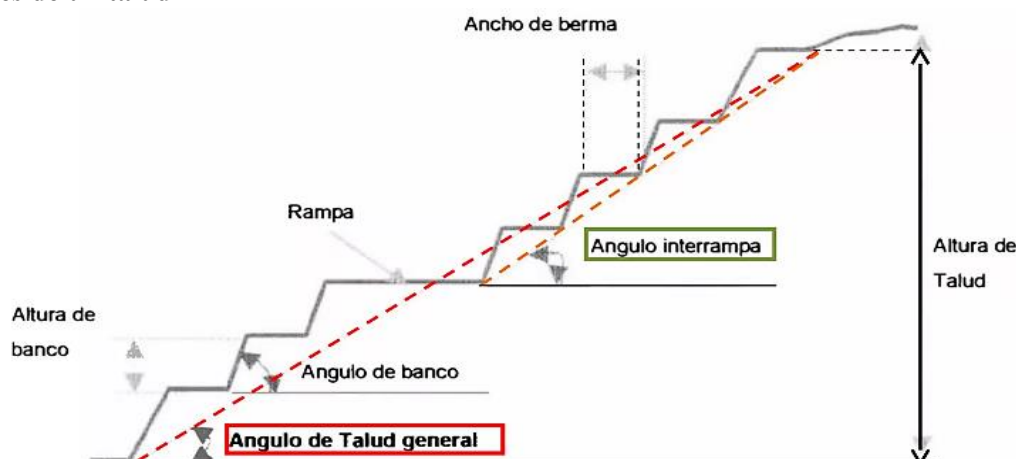


Figura 1. Partes de un talud

En la Figura 1, se puede observar el talud y sus partes correspondientes de como un talud se da en la mina superficial, que hay 2 diferentes variables clasificadas en los ejes x e y, y hay una incógnita en el medio lo cual el factor de seguridad debe de ser $FS \geq 1.5$ estable, $1.20 \leq FS < 1.5$ poco estable, $FS \leq 1.20$ inestable. Al comienzo, la separación entre este lugar desconocido y los demás lugares está determinada por el valor de K, lo que restringirá la cantidad de datos que se examinan, lo que indica cuántos vecinos cercanos se deben considerar al analizar según los parámetros establecidos [4].

La seguridad, la eficacia funcional y la rentabilidad de las actividades mineras dependen en gran medida de la estabilidad de los taludes en minas a cielo abierto. A lo largo del tiempo, se han creado y puesto en práctica varias estrategias para medir y asegurar la estabilidad de estas pendientes. Uno de los enfoques más comunes es el método de equilibrio límite, conocido por su facilidad de uso y su eficacia en diversas situaciones geotécnicas [5].

2.2. Calificación de la Calidad rocosa.

Este análisis examinó la consistencia de dichos pendientes a través de técnicas de geomecánica RQD. La estrategia abarcó investigaciones en el terreno para la identificación geológica y geotécnica [6].

Tabla 1. Calidad de roca (RQD)

Calidad de roca	RQD (%)
deficiente	<25
bajo	25 – 50
Regular	50 – 75
Buena	75 – 90
Excelente	90 - 100

2.3. Índice de Q de Barton

El Q Barton contribuye a anticipar el soporte y la tensión de taludes excavados en roca ofreciendo directrices sobre el ángulo de inclinación seguro. El Q utiliza los siguientes elementos para su evaluación: calidad de la roca (RQD), la cantidad de familias de juntas (J_n), el índice de rugosidad de juntas (J_r), el índice de juntas alteradas (J_a), las condiciones geológicas (J_{wice}), y el factor que reduce la resistencia del talud [7].

Tabla 2. Q Barton

Calidad de roca (Q)	Valoración
0.01 – 0.01	Críticamente deficiente
0.01 – 0.1	Muy deficiente
0.1 – 1	Altamente deficiente
1 – 4	Deficiente
4 – 10	Moderada
10 – 40	Favorable
40 – 100	Altamente favorable
100 – 400	Muy eficiente
400 - 1000	De calidad excepcional

2.4. Índice de Resistencia Geológica (GSI)

La simplicidad del sistema GSI resulta ser su principal desventaja, puesto que únicamente mide el nivel de fracturación del bloque rocoso y la condición de las superficies de las discontinuidades [8].

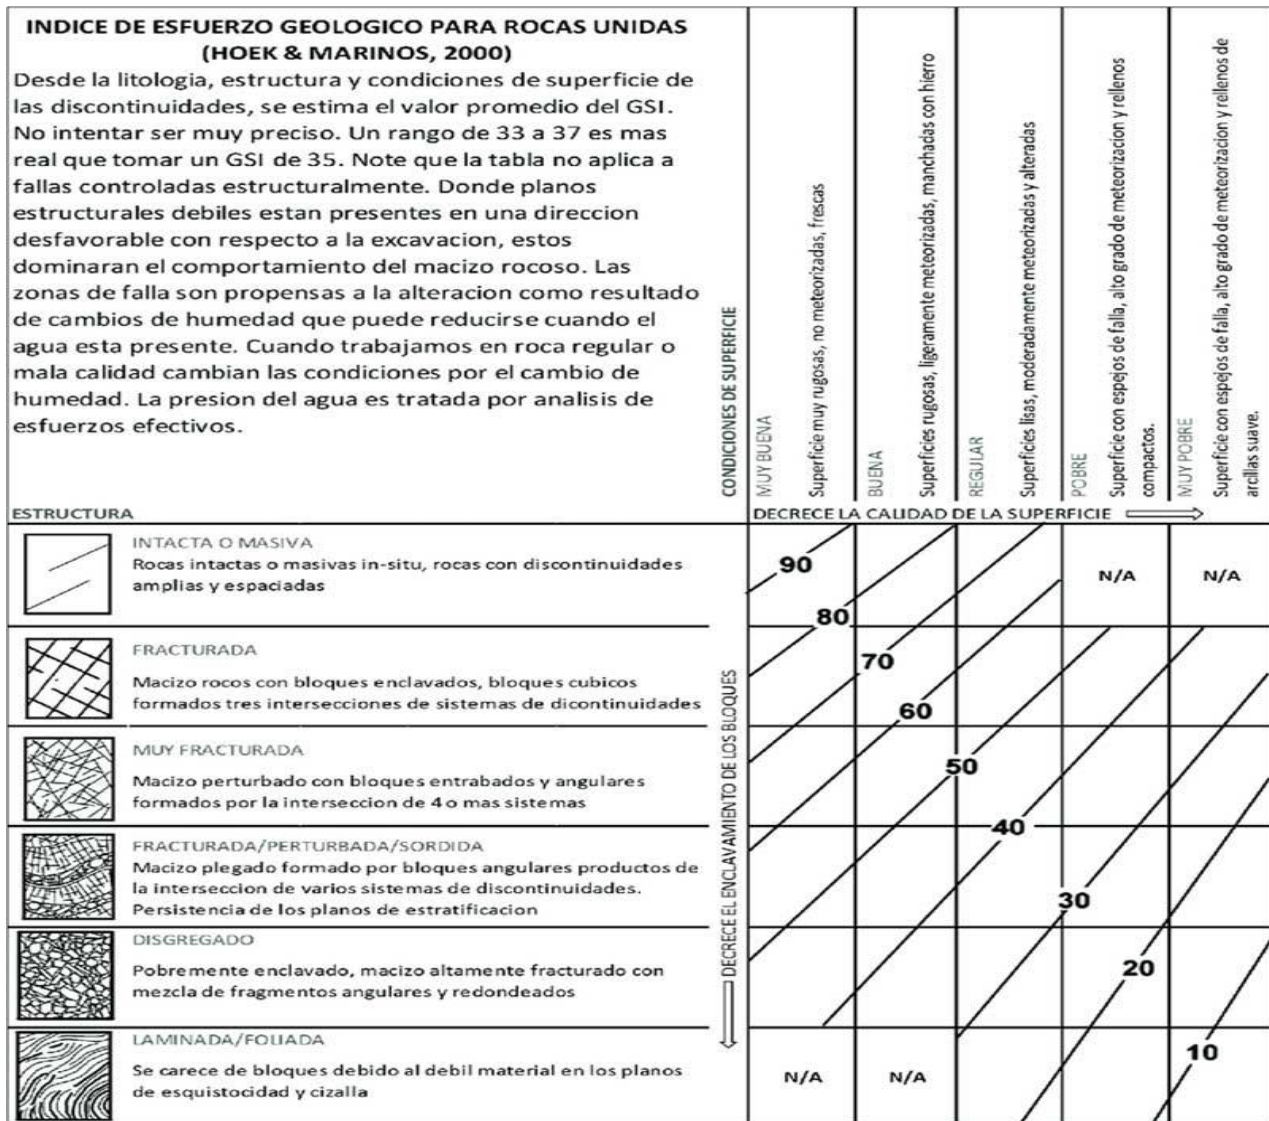


Figura 2. Índice de esfuerzo (GSI)

2.5. K-Nearest Neighbors (KNN)

KNN se describe como una técnica de predicción en el ámbito del aprendizaje supervisado que se basa en la distancia entre la muestra actual y los vecinos más cercanos que se establecen con un valor de k. Esto determina el resultado de la predicción realizada [9].

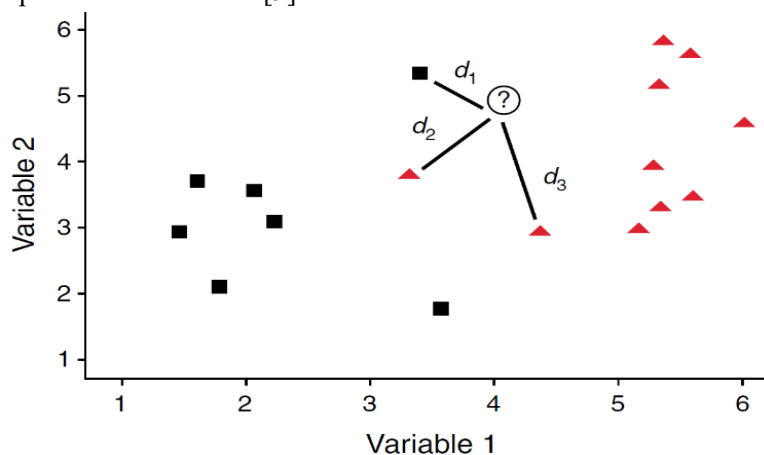


Figura 3. K - vecinos más cercanos

En Figura 3, se muestra que K es igual a 3 teniendo en cuenta el conjunto de información, se puede identificar la categoría de un dato en particular al medir su cercanía con otras muestras. Hay varios enfoques para calcular esa cercanía, siendo la distancia euclidiana el método más común usado para evaluar la separación entre dos ubicaciones [10].

$D(x,y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}$	(1)
---	-----

Donde - $D(x,y)$ distancia métrica de 2 puntos

x, y – variables específicas

n – cantidad de dimensiones

Tras establecer el valor de k y haberse entrenado el modelo KNN, se utilizó este método para anticipar el riesgo de colapso en pendientes con características distintas, limitándose a comparar los atributos del nuevo dato con aquellos del conjunto de datos que sirvió para el entrenamiento [11].

2.5.1. Matriz de confusión

Se empleó para examinar el desempeño específico de cada modelo en relación con las distintas clases de rocas. Este cuadro compila las predicciones correctas en comparación con las incorrectas, facilitando la detección de sesgos en la clasificación, confusión entre litologías parecidas y fallos recurrentes sistemáticos [12].

2.5.2. Métricas de Rendimiento.

$\text{Exactitud} = \frac{TP + TN}{TP + TN + FP + FN}$	(2)
--	-----

Donde:

TP – Positivos identificados

TN – Aciertos negativos

FP – Positivas erróneas

FN – Negativos clasificados

$\text{Precisión positiva} = \frac{TP}{TP + FP}$	(3)
--	-----

$\text{Sensibilidad} = \frac{TP}{TP + FN}$	(4)
--	-----

$\text{F1 - Score} = 2 * \frac{\text{Precisión} * \text{Recall}}{\text{Precisión} + \text{Recall}}$	(5)
---	-----

2.6. Descripción de datos y de cómo lo vamos a procesar en KNN.

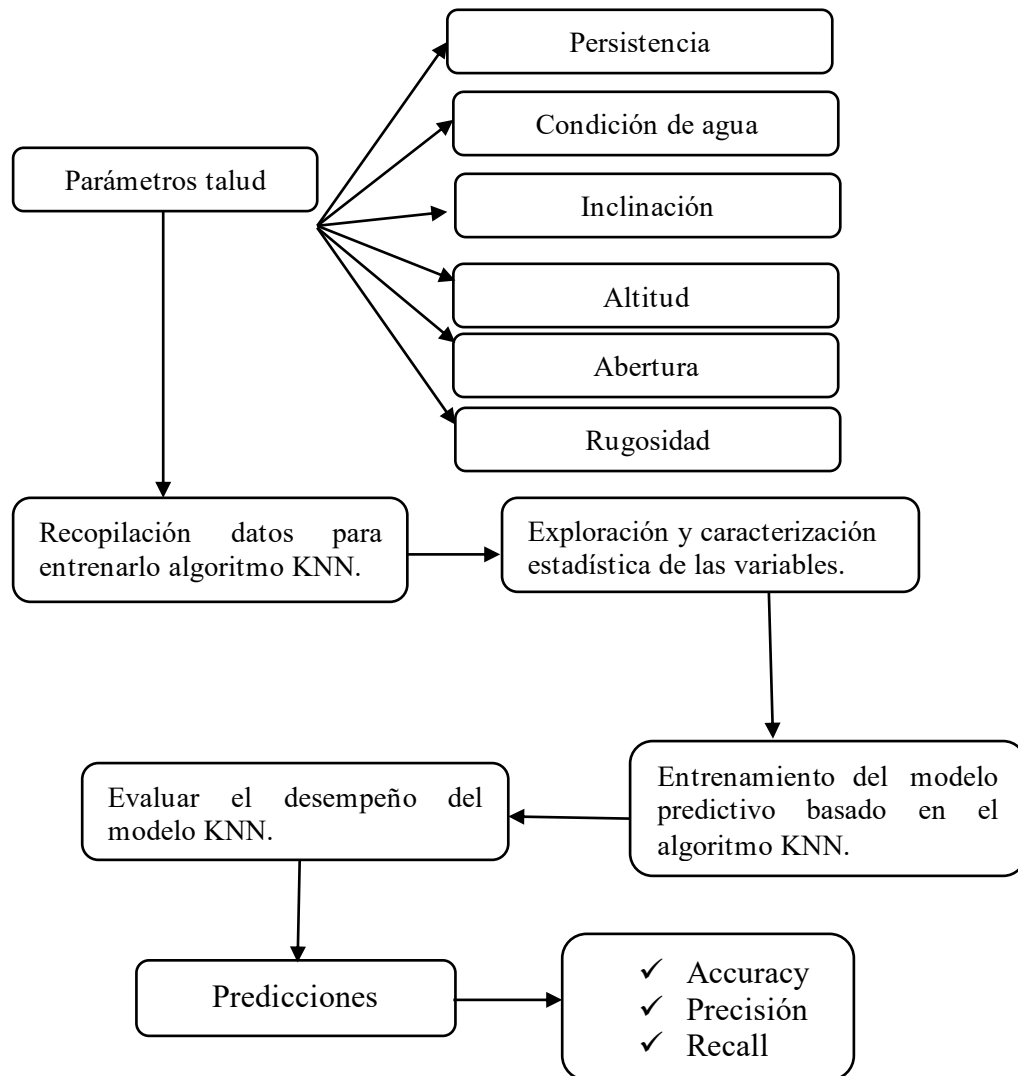


Figura 4. Flujograma de datos

2.7. Instrumentación y técnicas de recolección de datos

Los instrumentos que se utilizaron para el manejo de datos de la mina a cielo abierto son: Brújula, clinómetro, martillo y fichas geotécnicas, lo cual se analizaron en tablas con información auténtica que ayudarán a detallar las propiedades de los taludes en las variadas muestras de roca. Las metodologías aplicadas se basarán en referencias técnicas y en múltiples documentos vinculados al análisis de deslizamientos de taludes [2].

Las variables utilizadas para la base de datos son:

H0: Longitud Persistencia de la discontinuidad (m).

H1: Espaciamiento de la discontinuidad (mm)

H2: Grado Rugosidad de la discontinuidad

H3: Dirección de la discontinuidad

H4: Roca Alterada.

H5: Agua subterránea.

H6: Elevación de la pendiente total (m)

H7: Grado de Inclinación talud global (°)

Tabla 3. Taludes con status FSB – 0 (ruptura inter-rampa)

H0	H1	H2	H3	H4	H5	H6	H7	STATUS
12.86	3.08	3.91	3.18	1.99	4.01	193	38.81	FSB
11.54	2.9	4.29	3.8	2.78	3.8	241.16	41.83	FSB
18.11	3.03	3.24	3.21	3.83	4.29	590.74	36.38	FSB
17.49	2.9	3.17	4.2	3.98	4.12	803.71	34.94	FSB
14.74	3.03	3.94	3.05	2.11	4.02	482.7	35.37	FSB
1.26	3.06	3.81	3.99	2.09	2.84	182.52	40.18	FSB
0.42	0.51	3.07	3.81	3.21	2.82	179.47	51.73	FSB
2.6	2.91	2.88	3.16	2.08	2.98	323.14	52.85	FSB
2.4	0.55	2.9	3.12	2	2.81	285.79	67.09	FSB
8.37	3.14	4.14	5.17	4.26	5.04	725.92	41.43	FSB
23.55	2.97	2.79	4.65	3.93	2.94	317.19	53.42	FSB
26.49	3.21	2.8	4.84	3.18	1.85	308.54	57.82	FSB
12.82	2.81	1.86	4.17	3.18	2.78	346.12	59.06	FSB
21.32	2.97	3.15	3.77	3.9	3.04	337.51	53.24	FSB
21.28	2.92	3.96	2.96	2.85	4.16	314.9	47.19	FSB
5.18	2.93	3.14	3.74	3.23	2.87	530.77	49.1	FSB
10.02	3.16	2.9	4.27	3.17	3.84	232.53	44.92	FSB
5.07	3.02	4.32	4.24	3.95	4.22	154.29	57.67	FSB
6.79	0.53	3.73	3.08	3.2	4.07	637.25	38.06	FSB
6.83	0.54	2.09	5.39	2.81	3.09	770.32	31.25	FSB
8.1	0.56	3.14	3	3.85	4.21	222.46	29.68	FSB
6.46	3.07	3.96	4.13	2.97	4.77	156.37	44.53	FSB
9.95	4.89	4.13	3.17	2.95	3.89	327.55	52.81	FSB
5.52	3.03	3.16	2.1	4.25	3.97	452.57	25.92	FSB
6.21	0.52	2.09	3.14	0.93	3.91	48.18	44.24	FSB
11.13	0.31	1.89	1.91	4.26	4	19.21	49.94	FSB
9.34	2.15	1.85	1.92	2.09	4.16	20.18	48.64	FSB

Tabla 4. Taludes con status OF – 1 (ruptura global)

H0	H1	H2	H3	H4	H5	H6	H7	STATUS
11.97	3.06	2.1	3.93	2.12	5.13	173.24	31.7	OF
25.91	6.58	3.23	5.06	2.08	3.81	199.4	39.51	OF
0.86	3.03	2.78	4.64	2.94	3.03	92.41	54.78	OF
0.66	2.84	2.94	5.22	1.91	2.05	169.17	46.29	OF
6.83	2.82	2.79	4.16	2.15	2.9	226.22	35.36	OF
7.05	3.19	2	3.75	2.03	1.93	18.82	44.45	OF
6.15	2.76	3.09	5.36	2.97	3.87	757.8	32.62	OF
6.17	2.84	1.97	5.01	3.09	3.12	730.55	40.94	OF
7.79	3.01	2.98	5.21	2.79	2.89	733.17	34.51	OF
10.47	3.09	3.08	3.76	2.88	2.96	209.34	32.69	OF
9.77	3.1	2.93	4.76	3.73	2.98	193.93	34.96	OF
14.41	3.15	2.03	3.69	3.07	3.88	194.94	31.43	OF
16.14	3.04	3.9	2.9	1.89	2.06	272.11	45.46	OF
18.54	3.01	3.03	3.06	2.8	3.05	454.51	29.89	OF

17.09	4.8	3.11	5.28	2.08	2.02	272.47	36.32	OF
18.02	4.76	2.84	4.07	2.15	3.1	593.75	35.22	OF
19.68	2.76	3.22	4.01	4.21	4.06	95.7	42.91	OF
5.46	3.09	3	4.26	3.14	3.01	267.51	32.94	OF
11.68	0.49	2.05	3.88	1.05	3.96	53.99	51.74	OF

Tabla 5. Taludes con status ST – 2 (estable)

H0	H1	H2	H3	H4	H5	H6	H7	STATUS
29.62	3.01	3.07	3.75	3.86	4.63	195.21	52.33	ST
21.19	2.99	3.81	0.98	3.04	5.22	206.07	34.99	ST
10.63	0.98	3.02	3.85	4.63	4.92	195.69	57.68	ST
9.9	1.11	3.17	4	4.87	4.95	216.99	59.08	ST
24.05	3.23	2.79	4.22	4.24	5.07	214.5	46.83	ST
22.75	0.98	3.98	2.82	3.76	5.37	202.68	45.29	ST
7.78	2.91	2.78	4.04	2.8	5.02	164.43	48.5	ST
2.38	1.26	3	2.93	4.16	4.64	185.61	47.66	ST
1.62	0.75	4.08	2.14	3.05	5.23	157.6	39.21	ST
1.66	1.52	3.85	3.19	3.03	5.01	166.75	42.59	ST
2.08	1.16	3.15	2.84	4.22	4.84	174.93	42.61	ST
6.74	3.06	4.07	2.14	3.94	5.18	427.23	34.56	ST
11.52	2.91	3.83	3.72	4.07	4.84	595.05	36.03	ST
13.81	3.08	3.21	1.94	3.17	5.17	443.64	37.58	ST
6.61	5.56	3.83	3.04	4.01	3.88	299.53	36.26	ST
12.76	2.82	3.86	3.19	2.82	3.7	361.48	32.25	ST
0.51	3.13	4.01	1.98	3.15	4.32	193.16	52.73	ST
0.71	0.56	3.73	3.21	2.84	3.98	95.51	51.89	ST
0.98	3.04	3.2	2.82	3.76	3.94	93.21	59.81	ST
6.48	2.77	4.18	2.95	2.87	4.14	237.66	38.5	ST
5.62	0.54	2.91	2.78	4.23	4.8	719.54	28.95	ST
4.16	0.56	1.84	3.82	2.99	4.85	715.32	33.95	ST
2.6	0.51	3.92	2.88	3.22	5.32	730.02	32.08	ST
1.84	0.52	3.71	1.94	3.94	4.86	309.78	51.53	ST
6.21	0.56	4.23	2.92	3.84	4.9	517.86	54.63	ST
3.09	2.83	5.1	2.08	4.09	4.08	464.84	57.3	ST
4.68	0.59	4.21	4.1	3.94	5.27	491.75	42.77	ST
4.48	3.01	4.14	3.02	3.75	4.8	509.84	58.35	ST
3.09	0.56	3.92	3.01	5.38	5.28	249.34	52.99	ST
3.29	0.57	3.97	3.22	4.14	4.9	331.28	52.83	ST
2.3	0.09	3.86	2.09	3.74	5.21	321.66	45.17	ST
2.24	0.52	3.17	1.93	4.26	3.89	118.05	41.86	ST
3.76	0.59	4.27	1.94	4.17	4.05	721.38	40.66	ST
3.32	0.58	3.88	2.05	3.2	3.98	713.13	37.76	ST
3.77	0.52	3.16	2.84	3.72	3.95	725.57	43.15	ST
2.97	0.1	4.21	1.84	4.02	4.69	237.7	33.74	ST
4.24	0.53	3.96	2.05	3.8	3.82	251.93	25.06	ST

3.71	3.01	4.05	2.82	3.98	4.72	104.27	41.82	ST
7.63	0.57	4.17	3.06	3.74	4.17	282.6	52.78	ST

2.7.1. Forma del manejo de datos

La información recolectada y evaluada acerca de los taludes en la minería a cielo abierto será analizada a través de la aplicación del método (KNN).

2.7.2. Procedimiento

Para utilizar el enfoque KNN en la previsión de colapso en pendientes, se empleó un conjunto de datos que incorpora detalles sobre las geotécnicas de la pendiente y del terreno. Con esta información, se capacitó el método KNN con el objetivo de evaluar el peligro de deslizamientos, tomando en cuenta las propiedades del terreno y el tipo de fallo que podría ocurrir en la pendiente del talud [13] .

3. Resultados

La persistencia se refiere al aumento de dimensiones de la discontinuidad y la abertura es la medida de distancia entre ellas.




Figura 5. Relación parámetros de Abertura vs Persistencia

Selección del K optimo con todas las variables de nuestra data calculado en Python.

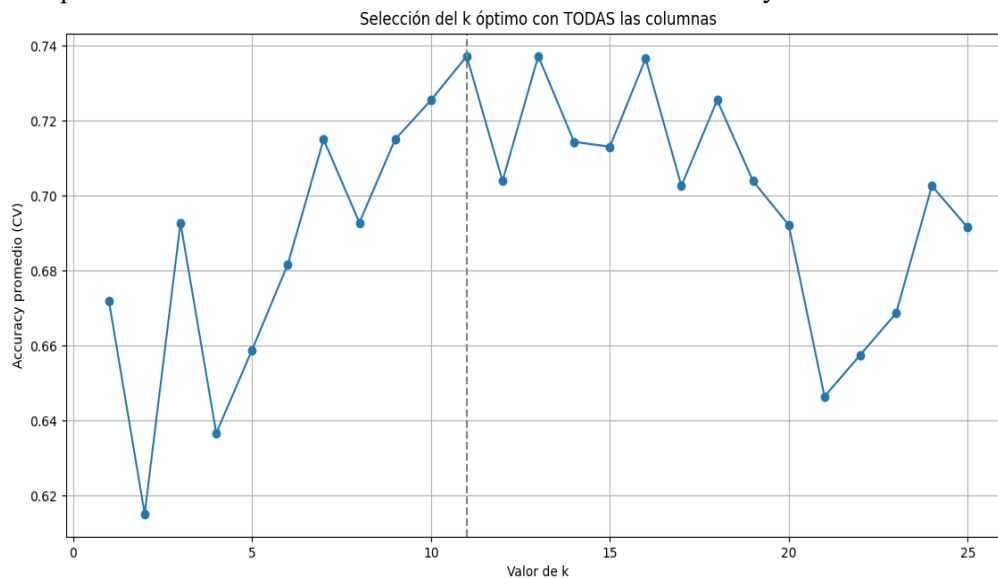


Figura 6. Valor de K=11, Accuracy promedio 73.73 %

3.1. Examinar la relación entre diversas características geotécnicas a través de KNN para anticipar deslizamientos

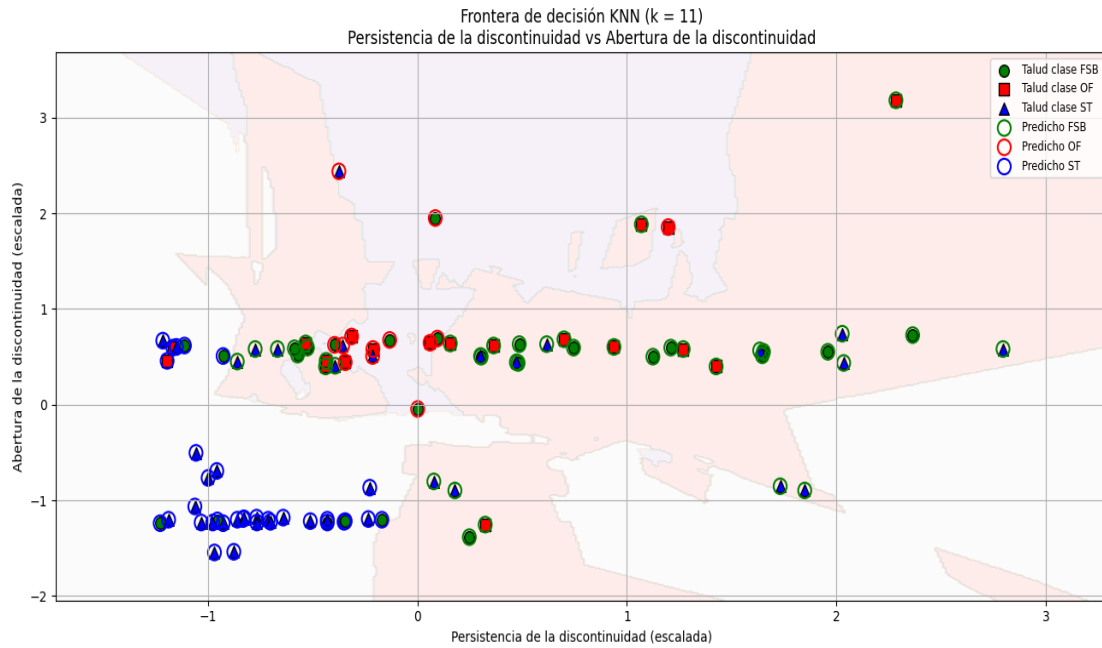


Figura 7. Abertura vs persistencia y sus predicciones.

En la Figura 7, indica que los taludes estables (ST) suelen concentrarse en áreas con menor apertura y una persistencia moderada, mientras que los inestables (FSB) se distribuyen en niveles más altos de persistencia o en combinaciones críticas de apertura. Los taludes de estabilidad media (OF) se sitúan entre estos dos conjuntos, lo que explica su posición intermedia en el límite del modelo.

Estas áreas son creadas por el algoritmo, el cual se basa en la proximidad de los puntos, tomando en cuenta los 11 vecinos más cercanos en un espacio de dos dimensiones.

Círculo azul vacío = ST pronosticado

Círculo rojo vacío = OF pronosticado

Círculo verde vacío = FSB pronosticado

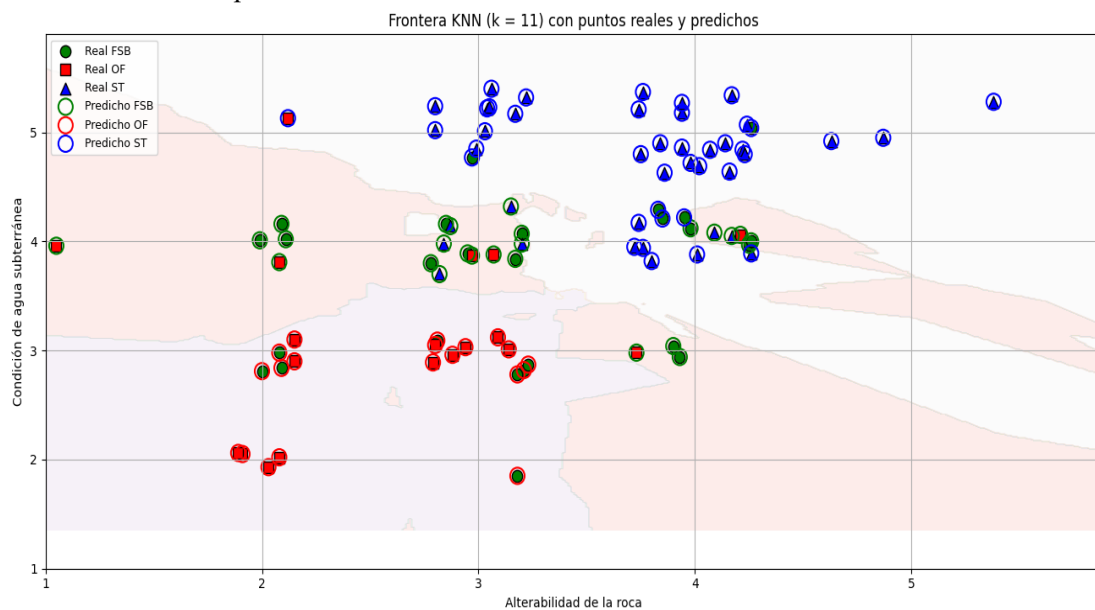


Figura 8. Condición agua vs Roca alterada

En general, en la Figura 8 muestra que el modelo KNN identifica correctamente las áreas donde existen taludes que son estables, parcialmente estables o inestables, logrando diferenciar claramente entre las categorías basándose en la combinación de la alterabilidad de las rocas y el estado del agua subterránea. La relación entre los datos reales y los estimados indica que el modelo tiene un rendimiento sólido en la clasificación de estas dos variables.

Parte superior derecha (baja alterabilidad y bajo nivel de agua subterránea).

ST (estables)

Parte central (alta alterabilidad y niveles de agua medianos).

FSB (inestables)

OF (estabilidad intermedia)




Figura 9. Inclinación vs Altitud y sus predicciones

En la Figura 9, ilustra que la fusión de la elevación total y la inclinación de la pendiente permite distinguir de manera efectiva las diversas categorías de estabilidad de los taludes. Los taludes que poseen baja elevación y una inclinación pronunciada suelen ser considerados inestables (FSB), mientras que los que tienen elevaciones superiores y pendientes moderadas se clasifican principalmente como estables (ST).

Taludes de baja elevación (0 – 150 m): OF (estabilidad media), algunos FSB (inestables)

Los taludes de menor altura y con inclinaciones elevadas tienden a ser considerados de estabilidad intermedia.

Taludes de elevación media (200 – 400 m): FSB (inestables), OF (media), ST (estables).

En las alturas medias, la inclinación se considera el factor más decisivo en la estabilidad.

Taludes de alta elevación (400 – 800 m): ST (estables).

3.2. Evaluar la efectividad del modelo KNN utilizando medidas de precisión en la clasificación y la matriz de confusión.

3.2.1. La matriz de confusión obtenida para el modelo KNN con k = 11.

<table style="margin: auto; border-collapse: collapse;"> <tr> <td style="padding: 2px 10px;">5</td> <td style="padding: 2px 10px;">1</td> <td style="padding: 2px 10px;">1</td> </tr> <tr> <td style="padding: 2px 10px;">0</td> <td style="padding: 2px 10px;">1</td> <td style="padding: 2px 10px;">0</td> </tr> <tr> <td style="padding: 2px 10px;">1</td> <td style="padding: 2px 10px;">0</td> <td style="padding: 2px 10px;">9</td> </tr> </table>	5	1	1	0	1	0	1	0	9	(1)
5	1	1								
0	1	0								
1	0	9								

3.2.1.1. Categoría FSB (Inestable) — fila 1

5 instancias se identificaron adecuadamente como FSB

1 instancia fue incorrectamente etiquetada como OF

1 instancia fue etiquetada erróneamente como ST

3.2.1.2. Categoría OF (Media) — fila 2

1 instancia real de OF se identificó correctamente como OF

No hubo fallos en esta categoría

3.2.1.3. Categoría ST (Estable) — fila 3

9 instancias se identificaron adecuadamente como ST

5 instancia fue etiquetada como FSB

3.2.2. Reporte optimo de estados del talud

Tabla 6. Reporte óptimo

	Precisión	Sensibilidad	F1 - Score	Support
FSB	0.83	0.71	0.77	7
OF	0.50	1.00	0.67	1
ST	0.90	0.90	0.90	10




Figura 10. Reporte de precisión y sensibilidad

En la Figura 10, se presenta un excelente desempeño del modelo.

3.2.2.1. Precisión

Mide las predicciones correctas hechas por el modelo.

FSB: 0.83

OF: 0.50

ST: 0.90

3.2.2.2. Recall (Sensibilidad)

Mide qué porcentaje de los casos que detecta correctamente reales el modelo

FSB: 0.71

OF: 1.00

ST: 0.90

3.2.2.3. F1-Score

Equilibrio de precisión y recall.

FSB: 0.77

OF: 0.67

ST: 0.90

3.2.3. Mediciones métricas globales.

Tabla 7 Mediciones de Exactitud, promedio macro y promedio ponderado

	Precisión	Sensibilidad	F1 - Score	Support
Exactitud			0.83	18
Promedio macro	0.74	0.87	0.78	18
Promedio ponderado	0.85	0.83	0.84	18

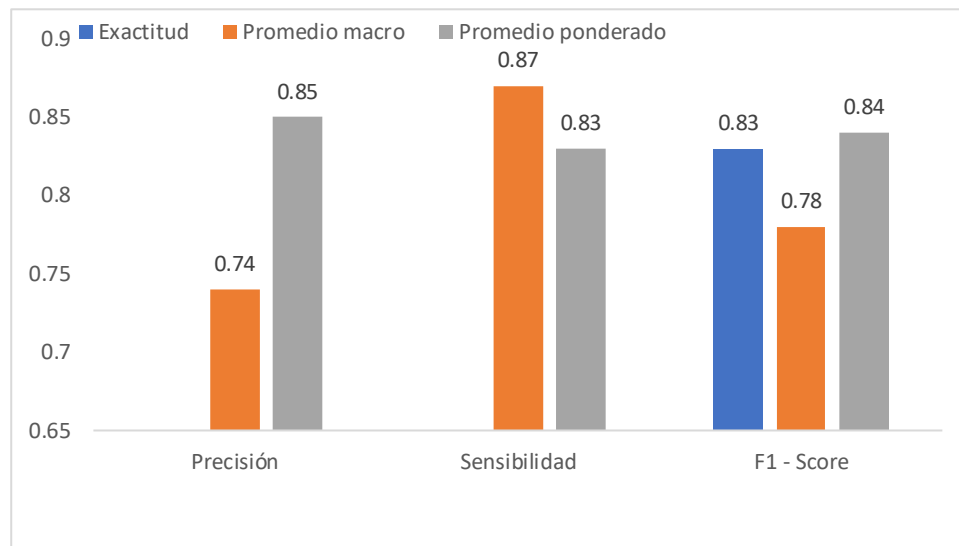


Figura 11. Precisión, sensibilidad y F1-score K=11

3.2.3.1. Macro Average.

Precisión: 0.74

Recall: 0.87

F1: 0.78

3.2.3.2. Weighted Average

Precisión: 0.85

Recall: 0.83

F1: 0.84

3.2.3.3. Accuracy (Exactitud): 83.33%

La matriz da un conjunto de datos que indica que el modelo KNN con k igual a 11 tiene un rendimiento satisfactorio en la clasificación de taludes (ST). Este modelo categoriza de manera correcta la mayor parte de los casos de las clases FSB (inestable) y ST (estable), mostrando altos valores tanto de precisión como de recuperación, especialmente en la clase ST (0.90).

3.3. Analizar cómo se distribuyen los datos en relación al ajuste del modelo y de prueba usando el K-Vecino más cercano para anticipar colapso de taludes.




Figura 12. Distribución de datos

En la Figura 12 se ilustra la distribución de los datos que refleja el comportamiento de todas las variables geotécnicas analizadas a través de las muestras del conjunto de entrenamiento. Cada línea en el gráfico representa una variable, facilitando la visualización de su variabilidad, rango y su conexión con otros parámetros. La persistencia abarca el rango más amplio de valores, mientras que la mayoría de las variables se agrupan entre 2 y 5 unidades. La línea que corresponde al objetivo permite identificar las transiciones de clase (FSB, OF y ST) y examinar cómo cambian las condiciones del talud en esos puntos. En general, este gráfico validará que las variables exhiben una distribución adecuada, sin la presencia de valores atípicos significativos y con una variabilidad suficiente, lo cual es esencial para el funcionamiento del algoritmo KNN que se basa en distancias.




Figura 13. Distribución de datos de prueba

En la Figura 13 se muestra el grupo de prueba cómo varían los parámetros geomecánicas que utiliza el algoritmo KNN para medir la estabilidad del talud. Se puede notar que las variables siguen patrones que son similares a los del grupo de entrenamiento, lo que sugiere que el modelo fue probado con datos que son característicos. Además, las modificaciones en la clase objetivo (estable, medio estable e inestable) se relacionan con cambios en la persistencia, apertura, alterabilidad y dirección de las discontinuidades, confirmando la relevancia del modelo para anticipar el comportamiento del talud en situaciones reales.

Tabla 8 predicciones con el modelo KNN desarrollado

Parámetros	Resultado
12.1, 2.2, 2, 4.1, 2, 5.2, 168, 48	0 (FSB)
12.3, 3.1, 4, 3, 2.2, 4, 188, 92	0 (FSB)
12.3, 3, 2.1, 4, 2, 5.3, 168, 31	1 (OF)
14, 1, 2, 6, 2, 5.1, 25.1, 26	2 (ST)
11.1, 3, 4.2, 1, 3, 5.2, 401, 36	2 (ST)
22.3, 3, 2, 1.2, 3, 5, 800, 42	0 (FSB)
17, 6.3, 2, 1, 2, 5, 501, 22	1 (OF)
13, 0.55, 3.1, 1, 3, 4, 503, 22	2 (ST)
20.1, 1, 4, 2.3, 3, 5, 401, 21	2 (ST)
18.1, 3, 5.2, 4, 3.1, 5, 661, 30.2	1 (OF)

En la Tabla 6 indica las predicciones desarrolladas por el algoritmo KNN, que de 10 taludes con sus parámetros dados se predice que hay una mayor estabilidad por 11 k vecinos cercanos de 7 taludes con una buena estabilidad.

4. Conclusiones

Los datos geotécnicos y geométricas como la persistencia, abertura, rugosidad, orientación de discontinuidades, roca alterada, condición del agua subterránea, altura e inclinación de la pendiente, con el fin de identificar los estados de estabilidad estable (ST), intermedio (OF) e inestable (FSB). Las predicciones que se realizó con el k- Nearest Neighbor (KNN donde K= 11 de 73.73 %, se desarrolló con las relaciones de los parámetros del talud y así saber si ese talud sería estable o presentaría deslizamientos.

Evaluar el desempeño del modelo (KNN) en la predicción de deslizamientos, mediante métricas de clasificación como precisión de 0.90, sensibilidad (recall) 0.90, F1-score 0.90 de estabilidad del talud (ST) y Accuracy (Exactitud): 83.33%, determinando la capacidad del modelo para clasificar correctamente los taludes.

La velocidad del método KNN deben ser relacionados con la cantidad de los siguientes datos de entrada y la cantidad de "vecinos cercanos, analizo la distribución de los datos con K=11, ayudo mucho en la asignación de los datos para calcular y crear el modelo a partir de los siguientes datos, para después comprobar su eficacia con los datos reservados para la prueba. Cabe considerar que los datos de entrenamiento represento el 83.33%, también nos da a indicar que con nuevos parámetros de 10 taludes se predice que hay una mayor estabilidad por 11 k vecinos cercanos de 7 taludes (ST y OF).

5. Conflicto de Intereses

El autor declara que no tiene conflicto de interés.

6. Referencias

- [1] V. Hanna Castro, «Evaluación de tecnologías hiperespectrales en la caracterización mineral de yacimientos para aplicaciones geometalúrgicas: Caso aplicado a Mina Florida, Distrito Minero Alhué, Región Metropolitana, Chile», 2017. <https://repositorio.uchile.cl/handle/2250/149764>
- [2] V. M. Cangussu, «Proposta de modelo de predição da condição de estabilidade de taludes de mina com uso do algoritmo K-Nearest Neighbors.», 2022. <http://www.monografias.ufop.br/handle/35400000/4105>

- [3] F. M. P. Reis, «Aplicação de técnicas de aprendizado de máquina para análise da condição de estabilidade de taludes de mina: redes neurais artificiais.», 2022. <http://www.monografias.ufop.br/handle/35400000/4525>
- [4] P. P. Catari Colque *et al.*, «Optimización del diseño de talud en minería superficial mediante el método de elementos finitos», *Rev. Digit. Novasenergía*, vol. 8, n.º 1, pp. 33-51, jun. 2025, doi: 10.37135/ns.01.15.09.
- [5] G. B. Frainz, «Análise da estabilidade de talude ferroviário sob influência de cargas e vibrações utilizando modelos de aprendizado de máquina», ago. 2024. <https://hdl.handle.net/1843/78421>
- [6] G. X. Mesquita, «Classificação geomecânica de taludes dos cânios do rio Poty segundo os sistemas RQD, Q, RMR e SMR», 2025. <http://repositorio.ufc.br/handle/riufc/80103>
- [7] D. B. Yáñez Borja y L. Jordá Bordehore, «Aplicación de la metodología de análisis empírico Q Slope para evaluación de taludes en la provincia Bolívar, caso de estudio vía Guaranda - Echeandía», Thesis, ESPOL. FICT, 2021. <http://www.dspace.espol.edu.ec/handle/123456789/53899>
- [8] «Modificación del Sistema GSI en función de la Escala de Análisis de Estabilidad de Taludes en Macizos Rocosos - ProQuest». <https://www.proquest.com/openview/d9d74ee783443d85b05bc6228d82d58a/1?pq-origsite=gscholar&cbl=2026366&diss=y>
- [9] S. Zhang, «Challenges in KNN Classification», *IEEE Trans. Knowl. Data Eng.*, vol. 34, n.º 10, pp. 4663-4675, oct. 2022, doi: 10.1109/TKDE.2021.3049250.
- [10] F. C. Canales Soto, «Aplicación y evaluación de modelos de machine learning y deep learning en la predicción de consumo energético en molinera SAG», 2024, <https://repositorio.uchile.cl/handle/2250/202615>
- [11] J. A. Pinedo Ramirez y F. J. Grados Acosta, «Modelo predictivo de planificación operativa bajo el enfoque de machine learning para gestionar los tiempos de ciclo del volquete en una mina subterránea», *Univ. Peru. Cienc. Apl. UPC*, nov. 2023, <https://repositorioacademico.upc.edu.pe/handle/10757/670723>
- [12] N. Arcila Quintero, «Predicción de alertas de falla para planes de monitoreo geotécnico aplicando el método del inverso de la velocidad acoplado con algoritmos de aprendizaje supervisado», nov. 2022. <https://repositorio.unal.edu.co/handle/unal/82998>
- [13] L. R. C. Silveira, M. S. Lana, y T. B. dos Santos, «Machine learning applied to the prediction of rockfall slope probability», *Res. Soc. Dev.*, vol. 11, n.º 10, pp. e89111032603-e89111032603, jul. 2022, doi: 10.33448/rsd-v11i10.32603.