

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

**FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y
CIVIL**

ESCUELA PROFESIONAL DE INGENIERÍA DE MINAS



TESIS:

**Predicción de la vida útil de la columna de perforación
basado en parámetros operativos mediante regresión
lineal múltiple en la Unidad Minera San Cristóbal, 2026**

Para optar el título profesional de:

INGENIERO DE MINAS

PRESENTADO POR:

Bach. Yemerson MAUCAYLLE LAUPA

ASESOR:

Dr. Ing. Fortunato DE LA CRUZ PALOMINO

AYACUCHO - PERÚ

2026

DEDICATORIA

A Dios, por conducirme en el camino del bien y permitirme
lograr cada uno de mis objetivos.

A mis padres Jorge y Estelista, por su incondicional amor y apoyo que han
sido el cimiento de mis sueños.

A mi pareja, Fiorela Urrutia, por su amor, comprensión y apoyo constante durante
este proceso, siendo una fuente de motivación para seguir adelante y alcanzar mis
metas.

AGRADECIMIENTO

Expreso mi más sincero agradecimiento a la Universidad Nacional de San Cristóbal de Huamanga, por haberme brindado la formación académica, profesional y humana necesaria para culminar satisfactoriamente esta etapa de mi vida profesional.

Asimismo, agradezco a mis profesores, quienes con sus conocimientos, experiencia y orientación contribuyeron de manera significativa en mi formación como profesional y en el desarrollo de la presente investigación.

De igual manera, expreso mi reconocimiento a la empresa contratista Rock Tools y a la Mina San Cristóbal, por brindarme las facilidades, el apoyo y la información necesaria para la ejecución de este trabajo de investigación.

Finalmente, agradezco profundamente a todas las personas que me apoyaron y acompañaron durante este proceso, ya sea con su orientación, motivación o confianza, contribuyendo de manera importante al logro de esta meta académica y profesional.

RESUMEN

La presente investigación tuvo como objetivo evaluar la vida útil de los componentes de la columna de perforación (shank, coupling, barra y broca) mediante modelos predictivos basados en los parámetros operativos y geomecánicos de la Unidad Minera San Cristóbal, durante 2026. Para ello, se aplicó la regresión lineal múltiple considerando como variables independientes la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. Metodológicamente, la investigación fue de tipo aplicada, de nivel explicativo, diseño no experimental y corte transversal. El procesamiento, entrenamiento, evaluación y validación estadística se realizaron en Python mediante Pandas, Scikit-learn y Statsmodels. En el conjunto de prueba, los modelos alcanzaron coeficientes de determinación de 0.9236 para el shank, 0.9760 para el coupling, 0.9288 para la barra y 0.9639 para la broca. La validación mediante mínimos cuadrados ordinarios obtuvo valores de R^2 de 0.9786, 0.9647, 0.9711 y 0.9659, respectivamente, con significancia estadística global en todos los modelos ($p < 0.001$). En el shank, las seis variables fueron estadísticamente significativas; en el coupling y la barra, resultaron significativas la presión de percusión, presión de avance, presión de aire y RMR; mientras que, en la broca, la presión de agua y el RMR alcanzaron significancia individual. Se concluye que la regresión lineal múltiple implementada en Python constituye una herramienta predictiva con elevada capacidad explicativa para apoyar la planificación del mantenimiento, el reemplazo oportuno de componentes y la gestión del consumo de aceros de perforación en la Unidad Minera San Cristóbal.

Palabras clave: regresión lineal múltiple, columna de perforación, vida útil de aceros, parámetros operativos, RMR, Unidad Minera San Cristóbal.

ABSTRACT

This study aimed to evaluate the service life of drill string components (shank, coupling, drill rod, and drill bit) using predictive models based on the operational and geomechanical parameters of the San Cristóbal Mining Unit during 2026. Multiple linear regression was applied, considering percussion pressure, rotation pressure, feed pressure, water pressure, air pressure, and Rock Mass Rating (RMR) as independent variables. Methodologically, this was an applied, explanatory-level study with a non-experimental, cross-sectional design. Data processing, model training, performance evaluation, and statistical validation were conducted in Python using Pandas, Scikit-learn, and Statsmodels. On the test dataset, the models achieved coefficients of determination of 0.9236 for the shank, 0.9760 for the coupling, 0.9288 for the drill rod, and 0.9639 for the drill bit. Validation using ordinary least squares yielded R^2 values of 0.9786, 0.9647, 0.9711, and 0.9659, respectively, with overall statistical significance in all models ($p < 0.001$). For the shank, all six variables were statistically significant. For the coupling and drill rod, percussion pressure, feed pressure, air pressure, and RMR were significant, whereas water pressure and RMR showed individual statistical significance for the drill bit. It was concluded that multiple linear regression implemented in Python constitutes a predictive tool with high explanatory power to support maintenance planning, the timely replacement of components, and drill steel consumption management at the San Cristóbal Mining Unit.

Keywords: multiple linear regression, drill string, drill steel service life, operational parameters, RMR, San Cristóbal Mining Unit.

ÍNDICE

DEDICATORIA.....	i
AGRADECIMIENTO.....	ii
RESUMEN.....	iii
ABSTRACT	iv
ÍNDICE	v
LISTA DE FIGURAS	xiv
LISTA DE TABLAS.....	xvii
LISTA DE ANEXO	xix
INTRODUCCIÓN.....	xx
CAPÍTULO I.....	1
I. PLANTEAMIENTO DEL PROBLEMA	1
1.1 Descripción del problema	1
1.1.1 A nivel internacional	1
1.1.2 A nivel nacional.....	2
1.1.3 A nivel Local	4
1.2 Formulación del problema	6
1.2.1 Formulación del problema general.....	6
1.2.2 Formulación de los problemas específicos.....	6
1.3 Objetivos.....	7
1.3.1 Objetivo general	7
1.3.2 Objetivos específicos.....	7

1.4	Justificación	7
1.4.1	Justificación teórica	7
1.4.2	Justificación metodológica	8
1.4.3	Justificación práctica	9
1.5	Importancia	9
1.6	Alcances y limitaciones	11
1.6.1	Alcances	11
1.6.2	Limitaciones	11
CAPÍTULO II.....		13
II. MARCO TEÓRICO.....		13
2.1	Antecedentes de la investigación	13
2.1.1	Antecedentes internacionales	13
2.1.1	Antecedentes nacionales.....	14
2.1.2	Locales.....	19
2.2	Bases teóricas.....	21
2.2.1	Perforación en minería subterránea	21
2.2.1	Jumbo de perforación	25
2.2.1.1	Evolución técnica y principios operativos.....	26
2.2.1.2	Componentes críticos del sistema de perforación	27
2.2.1.3	Clasificación sistémica de los jumbos de perforación.....	28
2.2.1.3.1	Clasificación por función operativa	28
2.2.1.3.2	Clasificación por sistema de propulsión y energía	29

2.2.1.3.3	Clasificación por configuración y tamaño de sección.....	29
2.2.1.3.4	Clasificación por marcas y modelos líderes	30
2.2.2	Columna de perforación	32
2.2.2.1	Broca	34
2.2.2.2	Barra	38
2.2.2.3	Coupling	40
2.2.2.4	Shank	41
2.2.3	Vida útil de herramientas de perforación	43
2.2.4	Parámetros de perforación.....	43
2.2.4.1	Parámetros operativos	43
2.2.4.1.1	Presión de percusión.....	43
2.2.4.1.2	Presión de avance	44
2.2.4.1.3	Velocidad de rotación.....	45
2.2.4.1.4	Presión de agua y barrido	46
2.2.4.2	Parámetros geomecánicos	47
2.2.4.2.1	Clasificación Geomecánica RMR (Rock Mass Rating)	47
2.2.4.2.2	Relación entre Geomecánica y Perforabilidad (DRI).....	48
2.2.4.3	Parámetros geométricos	49
2.2.4.3.1	Diámetro de Broca.....	49
2.2.4.3.2	Profundidad del taladro y avance lineal	50
2.2.5	Modelos de regresión	50
2.2.5.1	Regresión lineal simple	50

2.2.5.2	Regresión lineal múltiple.....	51
2.3	Generalidades de la unidad minera.....	52
2.3.1	Ubicación.....	53
2.3.2	Accesibilidad	54
2.3.3	Geología	57
2.3.3.1	Geología regional	57
2.3.3.2	Geología estructural	57
2.3.3.3	Geología local.....	58
2.3.4	Tipo de yacimiento.....	58
2.3.4.1	Mineralización.....	59
2.3.5	Reservas.....	59
2.4	Método de explotación.....	59
CAPÍTULO III		61
III. MATERIALES Y MÉTODOS		61
3.1	Tipo de investigación.....	61
3.2	Nivel de investigación	61
3.3	Diseño de investigación	61
3.4	Población y muestra.....	61
3.4.1	Población	61
3.4.2	Muestra	62
3.5	Formulación de hipótesis.....	62
3.5.1	Hipótesis general	62

3.5.2	Hipótesis específicas	62
3.6	Variables e indicadores.....	62
3.6.1	Variable independiente (X)	62
3.6.2	Variable dependiente (Y)	63
3.7	Operacionalización de variables	63
3.8	Técnica e instrumentos de recolección de datos	65
3.8.1	Técnica de recolección de datos	65
3.8.2	Instrumentos de la recolección de datos	65
3.8.3	Procesamiento de datos	66
CAPÍTULO IV		67
IV. RESULTADO Y DISCUSIÓN.....		67
4.1	Descripción del conjunto de datos	68
4.2	Explicación del código.....	69
4.2.1	Entrenamiento.py.....	70
4.2.1.1	Importación de bibliotecas	70
4.2.1.2	Carga de la base de datos	71
4.2.1.3	Selección de las variables de estudio	72
4.2.1.4	Eliminación de datos faltantes.....	72
4.2.1.5	Definición de la variable dependiente e independientes	72
4.2.1.6	División de los datos en entrenamiento y prueba.....	73
4.2.1.7	Estandarización de las variables independientes.....	74
4.2.1.8	Transformación del conjunto de prueba	75

4.2.1.9	Creación y entrenamiento del modelo.....	75
4.2.1.10	Obtención del intercepto y los coeficientes.....	76
4.2.1.11	Generación de predicciones.....	76
4.2.1.12	Evaluación del desempeño predictivo.....	77
4.2.1.13	Representación gráfica de los valores reales y predichos	77
4.2.1.14	Almacenamiento del modelo entrenado	78
4.2.2	Analisis_Statsmodels.py.....	79
4.2.2.1	Importación de las bibliotecas.....	79
4.2.2.2	Carga de la base de datos	80
4.2.2.3	Selección de las variables utilizadas en el análisis.....	80
4.2.2.4	Eliminación de datos faltantes.....	81
4.2.2.5	Definición de la variable dependiente e independientes	81
4.2.2.6	División de la base de datos	82
4.2.2.7	Estandarización de las variables independientes.....	83
4.2.2.8	Incorporación del término independiente.....	84
4.2.2.9	Creación del modelo OLS	85
4.2.2.10	Ajuste del modelo estadístico.....	85
4.2.2.11	Obtención del resumen estadístico completo	86
4.2.2.12	Extracción de los parámetros estadísticos	87
4.2.2.13	Cálculo del coeficiente de determinación	88
4.2.2.14	Cálculo del R^2 ajustado	88
4.2.3	Predecir.py.....	89

4.2.3.1	Carga del modelo y del escalador.....	89
4.2.3.2	Ingreso de nuevos datos	89
4.2.3.3	Estandarización de los nuevos datos	90
4.2.3.4	Generación de la predicción	90
4.3	Desarrollo del Modelo 1: Shank	91
4.3.1	Entrenamiento y evaluación del modelo de regresión lineal múltiple para el shank(Entrenamiento.py)	91
4.3.2	Validación estadística del modelo (Análisis_Statsmodels.py)	94
4.3.3	Aplicación del modelo para la predicción de la vida útil del shank (Predecir.py).....	97
4.4	Desarrollo del Modelo 2: Coupling	99
4.4.1	Resultados del entrenamiento y evaluación del modelo de regresión lineal múltiple para el coupling (Entrenamiento.py).....	99
4.4.2	Validación estadística del modelo (Análisis_Statsmodels.py)	103
4.4.3	Aplicación del modelo para la predicción de la vida útil del coupling (Predecir.py).....	107
4.5	Desarrollo del Modelo 3: Barra	109
4.5.1	Entrenamiento y evaluación del modelo de regresión lineal múltiple para la barra (Entrenamiento.py).....	109
4.5.2	Validación estadística del modelo (Análisis_Statsmodels.py)	112
4.5.3	Aplicación del modelo para la predicción de la vida útil de la barra (Predecir.py).....	116

4.6	Desarrollo del Modelo 4: Broca.....	117
4.6.1	Resultados del entrenamiento del modelo de regresión lineal múltiple para la broca (Entrenamiento.py).....	117
4.6.2	Validación estadística del modelo (Analisis_Statsmodels.py).....	120
4.6.3	Aplicación del modelo para la predicción de la vida útil de la broca (Predecir.py).....	123
4.7	Comparación de los cuatro modelos de regresión lineal múltiple	125
4.7.1	Comparación del desempeño predictivo de los modelos	125
4.7.2	Comparación de las ecuaciones de regresión obtenidas.....	128
	CONCLUSIONES.....	131
	RECOMENDACIONES	133
	REFERENCIA BIBLIOGRÁFICA	134
V.	ANEXOS	138
5.1	Anexo 1: Matriz de consistencia.....	138
5.1	Anexo 2: Código par el Shank.....	139
5.1.1	Entrenamiento.py.....	139
5.1.2	Analisis_Statsmodels.py.....	143
5.1.3	Predecir.py.....	145
5.2	Anexo 3: Código par el Coupling.....	148
5.2.1	Entrenamiento.py.....	148
5.2.2	Analisis_Statsmodels.py.....	152
5.2.3	Predecir.py.....	154

5.3	Anexo 4: Código par la Barra	157
5.3.1	Entrenamiento.py.....	157
5.3.2	Analisis_Statsmodels.py.....	161
5.3.3	Predecir.py.....	163
5.4	Anexo 5: Código par la Broca	166
5.4.1	Entrenamiento.py.....	166
5.4.2	Analisis_Statsmodels.py.....	170
5.4.3	Predecir.py.....	172
5.5	Anexo 6: Galería de fotografías.....	175
5.6	Anexo 7: Base de datos, reporte, diagrama de flujo, parámetros de operación.....	178

LISTA DE FIGURAS

Figura 1	Shank en estado de cambio	5
Figura 2	Rimadoras afilada listo para su reutilización	5
Figura 3	Broca de perforación desgastada	6
Figura 4	Perforadora de martillo de cabeza Atlas Copco.....	22
Figura 5	Perforadora con martillo de fondo Arlas Copco	23
Figura 6	Perforación rotativa Atlas Copco.....	24
Figura 7	Distribución de los botones en una broca de perforación.....	25
Figura 8	Jumbo Epiroc de dos brazos	26
Figura 9	Columna de perforación en frentes	33
Figura 10	Partes de la broca rotopercutiva.....	35
Figura 11	Mecanismo de fragmentación de broca de perforación	36
Figura 12	Tipos de caras de brocas a botones	37
Figura 13	Relación de la abrasividad y el tipo de broca	37
Figura 14	Tipos de hilos de barra en rosca.....	39
Figura 15	Barras hexagonales	39
Figura 16	Manguito de acoplamiento o coupling.....	41
Figura 17	Shank y sus diferentes configuraciones	42
Figura 18	Mina San Cristóbal	53
Figura 19	Mapa de ubicación nacional de la Mina San Cristóbal.....	54
Figura 20	Mapa de ubicación de la Mina San Cristóbal	55
Figura 21	Plano de accesibilidad en la Mina San Cristóbal	56

Figura 22 Comparación entre la vida útil real y la vida útil predicha para el modelo del shank	93
Figura 23 Resumen estadístico del modelo de regresión lineal múltiple para la vida útil del shank	95
Figura 24 Predicción de la vida útil del shank mediante el modelo de regresión lineal múltiple.	98
Figura 25 Resultado de la ejecución del código para el coupling.....	100
Figura 26 Comparación entre la vida útil real y la vida útil predicha para el modelo del coupling.....	103
Figura 27 Resumen estadístico del modelo de regresión lineal múltiple para la vida útil del coupling	104
Figura 28 Predicción de la vida útil del coupling.....	108
Figura 29 Resultado de la ejecución del código para la barra.....	109
Figura 30 Comparación entre la vida útil real y la vida útil predicha para el modelo de la barra.....	112
Figura 31 Resumen estadístico del modelo de regresión lineal múltiple para la vida útil de la barra.....	113
Figura 32 Predicción de la vida útil de la barra mediante el modelo de regresión lineal múltiple.	117
Figura 33 Resultado de la ejecución del código para la broca	118
Figura 34 Comparación entre la vida útil real y la vida útil predicha para el modelo de la broca	119

Figura 35 Resumen estadístico del modelo de regresión lineal múltiple para la vida útil de la broca.....	120
Figura 36 Predicción de la vida útil de la broca mediante el modelo de regresión lineal múltiple.	124
Figura 37 Comparación del coeficiente de determinación (R^2) de los cuatro modelos de regresión lineal múltiple.	126

LISTA DE TABLAS

Tabla 1 Componentes críticos del sistema de perforación	27
Tabla 2 Modelos más representativos de Epiroc	30
Tabla 3 Modelos más representativos de Sandvik	31
Tabla 4 Modelos más representativos de Resemin.....	32
Tabla 5 Parámetros del martillo	34
Tabla 6 Tipos de botones.....	36
Tabla 7 Configuración del shank.....	42
Tabla 8 Presión de percusión.....	44
Tabla 9 Clasificación de macizo rocoso mediante RMR	48
Tabla 10 Operacionlizacion de variables	64
Tabla 11 Variables independientes y dependientes para el entrenamiento del modelo68	
Tabla 12 Coeficientes del modelo de regresión lineal múltiple para la predicción de la vida útil del shank.....	91
Tabla 13 Métricas de evaluación del modelo de regresión lineal múltiple	92
Tabla 14. Coeficientes estimados del modelo de regresión lineal múltiple para el shank	96
Tabla 15 Parámetros operativos utilizados para la predicción de la vida útil del shank	98
Tabla 16 Indicadores de desempeño del modelo para la vida útil del coupling.	101

Tabla 17 Coeficientes estimados del modelo de regresión lineal múltiple para el coupling.....	105
Tabla 18 Parámetros operativos utilizados para la predicción de la vida útil del coupling.....	107
Tabla 19 Indicadores de desempeño del modelo de regresión lineal múltiple para la vida útil de la barra.....	110
Tabla 20 Coeficientes estimados del modelo de regresión lineal múltiple para la barra	114
Tabla 21 Coeficientes estimados del modelo de regresión lineal múltiple para la broca	121
Tabla 22 Predicción de la vida útil de la broca mediante el modelo de regresión lineal múltiple	124
Tabla 23 Comparación de los indicadores de desempeño de los modelos de regresión lineal múltiple.....	125
Tabla 24 Comparación de las ecuaciones de regresión lineal múltiple obtenidas.	128

LISTA DE ANEXO

Tabla 25	Matriz de consistencia	138
Figura 38	Boca mina RP 300 Mina San Cristóbal	175
Figura 39	Fotografía de mi persona despues de la charla seguridad.....	175
Figura 40	Afilado de brocas	176
Figura 41	Charla de capacitación al personal.....	176
Figura 42	Transporte del acero de perforación a interior mina.....	177
Figura 43	Control de identidad en el tablero de control.....	177
Figura 44	Base de datos	178
Figura 45	Reporte de operacines de equipo	180

INTRODUCCIÓN

En la industria minera subterránea moderna, la perforación de rocas constituye la unidad operativa primaria y crítica del ciclo de minado. De su correcta ejecución depende la eficiencia de las fases subsiguientes de voladura, carguío y transporte. Dentro de este proceso, la columna (integrada por Shank , las barras, el coupling y las brocas) se encuentra sometida de forma continua a sollicitaciones mecánicas severas, tales como ondas de impacto por percusión, fuerzas de empuje por avance, momentos flectores y desgaste por atrición en presencia de fluidos de barrido y detritos abrasivos.

En la Unidad Minera San Cristóbal, la variabilidad geomecánica de las labores subterráneas, caracterizada por diversos niveles de calidad de macizo rocoso (RMR), sumada a las fluctuaciones en los regímenes de operación del equipo de perforación (presiones de percusión, rotación, avance, agua y aire), genera patrones heterogéneos de fatiga y desgaste en los aceros. Tradicionalmente, la gestión del reemplazo de estos componentes se ha basado en criterios empíricos o en recomendaciones genéricas de los fabricantes, lo que frecuentemente deriva en fallas prematuras no programadas, paradas no planificadas de la maquinaria y un incremento sustancial en los costos operativos por metro perforado.

Frente a esta problemática, la aplicación del análisis de datos y la modelación basada en machine learning ofrece un enfoque innovador y de alto impacto técnico. La Regresión Lineal Múltiple (RLM), implementada mediante el lenguaje de programación Python y sus librerías especializadas (statsmodels, scikit-learn, pandas, etc.), permite cuantificar de manera rigurosa la influencia individual e interactiva de los parámetros operativos y geomecánicos sobre la durabilidad efectiva de los aceros. Esta herramienta brinda la capacidad de predecir la vida útil de cada componente de la columna de perforación con un elevado grado de precisión estadística.

El propósito fundamental de la presente investigación es formular, validar e implementar modelos matemáticos, basado en machine learning de regresión lineal múltiple ajustados a la realidad operativa de la Unidad Minera San Cristóbal para el periodo 2026. A través de este trabajo, se busca dotar al área de Operaciones y Mantenimiento de una herramienta predictiva confiable que permita fundamentar la toma de decisiones, optimizar la gestión de repuestos y estandarizar las presiones de trabajo en función del tipo de roca.

Estructuralmente, el presente informe de tesis se encuentra organizado de la siguiente manera:

- **Capítulo I:** El Problema de investigación, donde se delimita la realidad problemática, se plantean la formulación del problema, los objetivos (general y específicos), la hipótesis y la justificación teórica, práctica y metodológica del estudio.
- **Capítulo II:** Marco teórico, que consolida los antecedentes de investigación locales, nacionales e internacionales, las bases teóricas relativas a la perforación de rocas, geomecánica y desgaste de aceros, así como el fundamento del modelo de Regresión Lineal Múltiple.
- **Capítulo III:** Metodología de la investigación, donde se detallan el tipo, nivel y diseño de investigación, la población y muestra, la matriz de operacionalización de variables, las técnicas e instrumentos de recolección de datos y la descripción del flujo analítico en Python.
- **Capítulo IV:** Resultados y Discusión, sección en la cual se exponen las ecuaciones predictivas obtenidas para cada componente (Shank, barra, coupling y broca), la verificación de los supuestos estadísticos de la regresión.

- **Capítulo V:** Conclusiones y Recomendaciones, donde se sintetizan los hallazgos principales en respuesta a los objetivos planteados y se proponen lineamientos prácticos e investigaciones futuras.

CAPÍTULO I

I. PLANTEAMIENTO DEL PROBLEMA

1.1 Descripción del problema

La industria minera enfrenta diversos desafíos operativos, entre los cuales destaca la necesidad de estimar de manera precisa la vida útil de la columna de perforación, compuesta principalmente por la broca, la barra y el shank, elementos fundamentales en el funcionamiento de equipos de perforación como los jumbos utilizados en minería subterránea a nivel mundial.

La determinación de la vida útil de estos componentes resulta compleja debido a la influencia de múltiples parámetros de perforación, tales como la presión de percusión, rotación, avance, agua y aire, el tipo de roca y las condiciones operativas. En este contexto, el uso de métodos estadísticos avanzados, como la regresión lineal múltiple, permite modelar la relación entre dichas variables y estimar valores más cercanos a la realidad, contribuyendo a una mejor planificación, reducción de costos operativos y optimización del rendimiento de los equipos.

1.1.1 A nivel internacional

A nivel mundial, diversos estudios han abordado la optimización de los procesos de perforación mediante el análisis de parámetros operativos y el uso de herramientas estadísticas y computacionales avanzadas, con el objetivo de mejorar la eficiencia y reducir costos en las operaciones mineras.

En este contexto, Nobahar et al. (2024) desarrollaron una metodología orientada a evaluar de los parámetros de perforación mediante el uso de algoritmos de aprendizaje automático y análisis de datos históricos. Su estudio tuvo como objetivo mejorar la eficiencia del proceso de perforación, logrando reducir el consumo de energía y los

costos operativos, lo cual evidencia la importancia de modelar adecuadamente las variables que intervienen en el proceso.

Por otro lado, Fattahi & Ghaedi (2024) propusieron mejorar la precisión en la estimación del Índice de Tasa de Perforación (DRI) mediante la aplicación del método del Sistema de Ingeniería de Rocas (RES). Este enfoque considera la incertidumbre y la naturaleza no lineal de las propiedades del macizo rocoso, lo que permite obtener resultados más representativos del comportamiento real durante la perforación.

Estos estudios demuestran que el análisis de parámetros de perforación mediante modelos matemáticos y estadísticos constituye una herramienta clave para la predicción y optimización del desempeño en operaciones mineras, sentando las bases para investigaciones orientadas a la estimación de la vida útil de los componentes de la columna de perforación.

1.1.2 A nivel nacional

A nivel nacional, diversas investigaciones se han enfocado en evaluar el rendimiento y la vida útil de los aceros de perforación, así como su impacto en los costos operativos y la eficiencia de las labores mineras, evidenciando la importancia de un adecuado control de los parámetros de perforación.

En este contexto, Alanya & Sarmiento (2025) analizaron la vida útil de los aceros de perforación y su influencia en los costos operativos en la Rampa 4200, destacando la importancia del control de parámetros operativos y la aplicación de técnicas adecuadas de perforación para mejorar el desempeño de los equipos.

Por su parte, Flores & Martinez (2023) evaluaron el rendimiento de herramientas de perforación cónicas, como barras y brocas, analizando la influencia de las prácticas operativas en el paralelismo de los taladros y la eficiencia del proceso, lo que repercute directamente en la durabilidad de los componentes.

Asimismo, Curasi & Quispe (2024) realizaron una evaluación del rendimiento y la vida útil de los aceros de perforación con el propósito de estimar su consumo mensual en labores de avance en la unidad minera SOTRAMI S.A., evidenciando la necesidad de contar con metodologías que permitan predecir su comportamiento en condiciones reales de operación.

De igual manera, Prieto & Patiño (2024) plantearon la reducción de costos de perforación mediante la optimización del uso de aceros T38 en el método sublevel stoping, a través de la implementación de procedimientos integrales de trabajo que mejoran la eficiencia operativa.

Por otro lado, Huamani (2023) determinó la influencia de la evaluación del rendimiento de la columna de perforación en la optimización de los costos por metro perforado en la Compañía Minera Volcan S.A.A. – Andaychagua, demostrando la relación directa entre el desempeño de los aceros y los indicadores económicos de la operación.

Finalmente, Barrientos (2022) desarrolló un estudio técnico-económico para la selección de barras de perforación en la Compañía Minera Aruntani – Unidad Santa Rosa, considerando como variables las características técnico-económicas, tales como el costo, la vida útil y el rendimiento, evidenciando su influencia en la toma de decisiones operativas.

En conjunto, estos estudios reflejan que, a nivel nacional, existe un interés creciente en optimizar el uso de los aceros de perforación; sin embargo, aún se evidencia la necesidad de desarrollar modelos predictivos que permitan estimar de manera precisa la vida útil de la columna de perforación en función de los parámetros operativos, lo cual constituye un vacío que la presente investigación busca abordar.


1.1.3 A nivel Local

A partir de la revisión de estudios a nivel mundial y nacional, se evidencia que, si bien existen avances en la optimización de los parámetros de perforación y en la evaluación del rendimiento de los aceros de perforación, aún persiste una limitada aplicación de modelos estadísticos que permitan estimar de manera precisa la vida útil de la columna de perforación en condiciones reales de operación. Investigaciones como las de Quito & Jaramillo (2020), así como Chavez (2024), han demostrado que el rendimiento y la vida útil de los aceros de perforación dependen significativamente de variables operativas y geomecánicas, tales como los parámetros de perforación, el estado de los equipos, el mantenimiento y la capacitación del personal; sin embargo, estos estudios se centran principalmente en el análisis operativo y no en el desarrollo de modelos predictivos robustos.

Esta situación genera incertidumbre en la planificación del mantenimiento, la reposición de componentes y el control de costos en las operaciones mineras. En este contexto, surge la necesidad de desarrollar un modelo basado en regresión lineal múltiple que permita relacionar los parámetros de perforación con la vida útil de la broca, la barra y el shank, contribuyendo a una estimación más confiable y a la optimización del proceso de perforación en la Unidad Minera San Cristóbal.

Figura 1

Shank en estado de cambio



Nota. Elaboración propia.

Figura 2

Rimadoras afilada listo para su reutilización



Nota. Elaboración propia.

Figura 3

Broca de perforación desgastada



Nota. Elaboración propia.

1.2 Formulación del problema

1.2.1 Formulación del problema general

¿En qué medida los parámetros operativos de perforación permiten predecir la vida útil de la columna de perforación mediante un modelo de regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026?

1.2.2 Formulación de los problemas específicos

1. ¿Como se estima la vida útil del shank en función de los parámetros de perforación mediante regresión lineal múltiple?
2. ¿Como se estima la vida útil del coupling en función de los parámetros de perforación mediante regresión lineal múltiple?

3. ¿Como se estima la vida útil de la barra en función de los parámetros de perforación mediante regresión lineal múltiple?
4. ¿Como se estima la vida útil de la broca en función de los parámetros de perforación mediante regresión lineal múltiple?

1.3 Objetivos

1.3.1 Objetivo general

Estimar la vida útil de la columna de perforación en función de los parámetros de perforación mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026.

1.3.2 Objetivos específicos

1. Estimar la vida útil del shank en función de los parámetros de perforación mediante regresión lineal múltiple.
2. Estimar la vida útil del coupling en función de los parámetros de perforación mediante regresión lineal múltiple.
3. Estimar la vida útil de la barra en función de los parámetros de perforación mediante regresión lineal múltiple.
4. Estimar la vida útil de la broca en función de los parámetros de perforación mediante regresión lineal múltiple.
5. Validar la precisión del modelo de regresión lineal múltiple mediante la comparación de la vida útil estimada frente a los datos reales de campo.

1.4 Justificación

1.4.1 Justificación teórica

La presente investigación se justifica desde el punto de vista teórico porque contribuye al fortalecimiento del conocimiento relacionado con la predicción de la vida útil de la columna de perforación mediante la aplicación de modelos de Regresión

Lineal Múltiple (RLM). Si bien existen investigaciones orientadas al análisis del rendimiento de los aceros de perforación y a la evaluación de los parámetros operativos durante la perforación, son limitados los estudios que integran simultáneamente variables operativas y geomecánicas para modelar matemáticamente el comportamiento de los principales componentes de la columna de perforación, como el shank, el coupling, las barras y las brocas.

En ese contexto, la investigación aporta evidencia científica sobre la relación existente entre la presión de percusión, la presión de avance, la presión rotación, la presión de agua, la presión de aire y la calidad del macizo rocoso (RMR) con la vida útil de los aceros de perforación, permitiendo ampliar la comprensión de los factores que influyen en su degradación durante las operaciones de perforación en minería subterránea. Asimismo, el estudio constituye un referente para futuras investigaciones relacionadas con la aplicación de modelos predictivos y técnicas de análisis estadístico en la optimización de procesos mineros.

1.4.2 Justificación metodológica

Desde el punto de vista metodológico, la investigación propone un procedimiento estructurado para el desarrollo y validación de modelos predictivos mediante Regresión Lineal Múltiple, utilizando registros históricos de operación provenientes de la Unidad Minera San Cristóbal. El proceso metodológico comprende la recopilación y depuración de la información, la selección de variables independientes y dependientes, el entrenamiento del modelo, la evaluación de su capacidad predictiva y la verificación de los supuestos estadísticos necesarios para garantizar la confiabilidad de las ecuaciones obtenidas.

Para el procesamiento de la información se emplean herramientas computacionales desarrolladas en Python, utilizando bibliotecas especializadas para análisis estadístico,

modelamiento y validación de resultados. Esta metodología proporciona un procedimiento reproducible y técnicamente sustentado que puede ser adaptado para la predicción de la vida útil de otros componentes o para investigaciones similares orientadas al análisis de procesos de perforación en minería subterránea.

1.4.3 Justificación práctica

La investigación se justifica de manera práctica porque proporciona una herramienta técnica que permite estimar la vida útil de los componentes de la columna de perforación antes de que estos alcancen estados críticos de desgaste, facilitando la toma de decisiones relacionadas con el mantenimiento, la programación del reemplazo de aceros de perforación y la planificación del consumo de materiales.

La implementación de modelos predictivos permitirá optimizar la gestión de los recursos empleados en la perforación, reducir pérdidas ocasionadas por fallas prematuras de los componentes, minimizar tiempos improductivos asociados al cambio de aceros y contribuir a la disminución de los costos operativos. Asimismo, la información generada constituye un soporte técnico para mejorar la planificación de las actividades de perforación y fortalecer la eficiencia operativa en la Unidad Minera San Cristóbal, favoreciendo una utilización más eficiente de los equipos y de los recursos destinados al proceso de perforación.

1.5 Importancia

La importancia de la presente investigación radica en que incorpora un enfoque predictivo basado en modelos de Regresión Lineal Múltiple para estimar la vida útil de la columna de perforación a partir de parámetros operativos y geomecánicas registrados durante las actividades de perforación en minería subterránea. A diferencia de los métodos convencionales, que generalmente se fundamentan en la experiencia del personal o en inspecciones posteriores al desgaste de los componentes, el modelo

desarrollado permite anticipar el comportamiento de los aceros de perforación mediante el análisis estadístico de datos históricos, contribuyendo a una gestión más eficiente del proceso de perforación.

Desde el punto de vista técnico, la investigación proporciona información objetiva acerca de la influencia que ejercen la presión de percusión, la presión de avance, la presión de rotación, la presión de agua, la presión de aire y la clasificación geomecánica del macizo rocoso (RMR) sobre la vida útil del shank, coupling, barras y brocas. Esta información facilita la optimización de los parámetros de operación y permite establecer estrategias orientadas a prolongar la vida útil de los componentes de la columna de perforación.

En el ámbito operativo, los resultados constituyen una herramienta de apoyo para la planificación del mantenimiento, la programación del reemplazo oportuno de los aceros de perforación y la gestión del consumo de materiales, reduciendo paradas no programadas y mejorando la continuidad de las operaciones. Asimismo, la implementación del modelo predictivo favorece una toma de decisiones basada en evidencia, incrementando la confiabilidad de la planificación operativa.

Finalmente, la investigación adquiere relevancia académica y científica porque demuestra la aplicabilidad de técnicas de análisis de datos y aprendizaje estadístico en la solución de problemas propios de la ingeniería de minas. De esta manera, promueve la incorporación de herramientas computacionales, como Python y la Regresión Lineal Múltiple, en la optimización de procesos mineros, constituyéndose en una referencia para futuras investigaciones relacionadas con la analítica de datos, el mantenimiento predictivo y la gestión inteligente de las operaciones de perforación.

1.6 Alcances y limitaciones

1.6.1 Alcances

La presente investigación se desarrolla en la Unidad Minera San Cristóbal durante el año 2026 y se enfoca en la predicción de la vida útil de la columna de perforación mediante la aplicación de modelos de Regresión Lineal Múltiple. El estudio comprende el análisis de los principales componentes de la columna de perforación: shank, coupling, barras y brocas, considerando como variables independientes la presión de percusión, la presión de avance, la presión de rotación, la presión de agua, la presión de aire y la clasificación geomecánica del macizo rocoso (RMR).

La investigación utiliza registros históricos de operación obtenidos durante las actividades de perforación en minería subterránea, los cuales son procesados mediante herramientas computacionales desarrolladas en Python para el entrenamiento, validación y evaluación de los modelos predictivos. Asimismo, el estudio incluye la formulación de ecuaciones de regresión, la evaluación de indicadores estadísticos de desempeño y la verificación de los supuestos de la Regresión Lineal Múltiple, con la finalidad de garantizar la confiabilidad de las predicciones obtenidas.

Los resultados están orientados a proporcionar una herramienta de apoyo para la gestión del consumo de aceros de perforación, la planificación del mantenimiento y la toma de decisiones relacionadas con el reemplazo oportuno de los componentes de la columna de perforación en la Unidad Minera San Cristóbal.

1.6.2 Limitaciones

La investigación se limita al análisis de la información histórica correspondiente a la Unidad Minera San Cristóbal, por lo que las ecuaciones obtenidas representan el comportamiento de las condiciones operativas y geomecánicas propias de dicha operación minera. En consecuencia, la aplicación de los modelos a otras unidades

mineras requiere un proceso previo de calibración y validación utilizando información específica de cada operación.

Asimismo, el modelo predictivo considera únicamente las variables operativas y geomecánicas definidas en la investigación; por tanto, no incorpora otros factores que también pueden influir en la vida útil de la columna de perforación, tales como la experiencia del operador, las condiciones de mantenimiento del equipo, las características metalúrgicas de los aceros de perforación, las condiciones ambientales, la calidad de fabricación de los componentes o variaciones propias del proceso operativo.

Finalmente, los resultados obtenidos corresponden al período de evaluación considerado en la investigación y dependen de la calidad, consistencia y disponibilidad de los registros utilizados para el entrenamiento y validación del modelo estadístico. En consecuencia, la precisión de las predicciones está condicionada por la representatividad de la información analizada y por el cumplimiento de los supuestos estadísticos propios de la Regresión Lineal Múltiple.

CAPÍTULO II

II. MARCO TEÓRICO

2.1 Antecedentes de la investigación

2.1.1 Antecedentes internacionales

Nobahar et al. (2024) desarrollaron un estudio orientado a la optimización del proceso de perforación con el objetivo de reducir costos y consumo de energía mediante la mejora de métricas clave como la tasa de penetración (ROP), el torque sobre la broca (TOB) y la energía específica mecánica (MSE). El estudio parte de la limitación de los métodos tradicionales, los cuales se basan en modelos físicos derivados de fórmulas o experiencia, pero presentan baja precisión en la predicción, lo que impide obtener parámetros óptimos de perforación. Para superar estas limitaciones, los autores propusieron un enfoque basado en aprendizaje automático y análisis de datos, empleando modelos construidos a partir de información de pozos desplazados, lo que permitió mejorar significativamente la precisión en la predicción de los parámetros de perforación. El modelo consideró como variables de entrada el peso sobre la broca (WOB), la velocidad de rotación (RPM), el flujo (FLW), la litología y la profundidad, sin necesidad de incorporar parámetros de mecánica de rocas. Los resultados del estudio evidenciaron que una selección inadecuada del WOB y RPM limita el incremento de la ROP, mientras que la optimización del flujo contribuye a mejorar la eficiencia del proceso de perforación. La aplicación de la metodología en un pozo objetivo permitió una reducción del 55% en la MSE, una disminución del 25% en el torque y un incremento del 20% en la ROP, demostrando la efectividad del enfoque propuesto.

Fattahi & Ghaedi (2024) realizaron un estudio enfocado en la estimación del Índice de Tasa de Perforación (DRI), un parámetro fundamental para evaluar la perforabilidad

de las rocas en proyectos de mecánica de rocas y minería. El estudio parte de la problemática asociada a la alta complejidad, no linealidad e incertidumbre de las propiedades físicas y mecánicas de las rocas, lo que dificulta el cálculo preciso del DRI y genera posibles errores en su estimación. Con el fin de mejorar la precisión en la predicción del DRI, los autores aplicaron el método del Sistema de Ingeniería de Rocas (RES), el cual permite modelar relaciones complejas y no lineales considerando la incertidumbre de los datos. Para ello, utilizaron información experimental correspondiente a 32 tipos de roca, evaluando seis parámetros influyentes: la prueba de perforación miniatura de Sievers (SJ), la prueba de fragilidad (S20), la resistencia a la tracción brasileña (BTS), la resistencia a la compresión uniaxial (UCS) y los índices de fragilidad B3 y B8. El modelo desarrollado fue validado mediante indicadores estadísticos como el error cuadrático medio (MSE), el coeficiente de determinación (R^2) y la raíz del error cuadrático medio (RMSE), comparando sus resultados con otros modelos de regresión. Los resultados demostraron que el método RES mejora significativamente la precisión en la estimación del DRI, constituyéndose como una herramienta eficaz para aplicaciones en ingeniería de rocas y minería.

2.1.1 Antecedentes nacionales

Alanya & Sarmiento (2025) realizaron un estudio en la Rampa 4200 de la Compañía Minera Ares Ayacucho S.A.C., enfocado en el análisis de la vida útil de los aceros de perforación con la finalidad de reducir los costos operativos en las actividades mineras. La investigación partió de la importancia que tiene el desempeño de los aceros de perforación en la productividad y en la optimización de costos dentro de la operación. Para el análisis, se consideraron datos geomecánicos del macizo rocoso con el fin de identificar el tipo de roca presente en la zona de estudio, así como variables operativas relacionadas con la frecuencia de afilado de brocas, el uso de grasas y el control de

parámetros de perforación. El estudio evaluó el comportamiento de los aceros de perforación antes y después de implementar controles operativos. Los resultados evidenciaron mejoras en el rendimiento de los componentes de perforación, como el shank, coupling y barras, reflejándose en un mayor número de pies perforados. Asimismo, se determinó que la velocidad de perforación depende directamente del estado de la broca, siendo mayor al inicio de su uso y disminuyendo progresivamente con el desgaste. En este contexto, el afilado de brocas se identificó como un factor clave para incrementar la vida útil de los aceros de perforación y reducir los costos operativos.

Curasi & Quispe (2024) realizaron una investigación en la unidad minera SOTRAMI S.A., enfocada en la evaluación de los aceros de perforación para proponer un consumo mensual en labores de avance durante el año 2023. El estudio tuvo como problema central determinar el resultado de la evaluación del rendimiento de los aceros de perforación y su influencia en la planificación del consumo mensual en las operaciones mineras. La investigación fue de tipo aplicada, con un nivel descriptivo correlacional y un diseño no experimental. La población y muestra estuvieron conformadas por diversas labores de avance y producción, incluyendo cruceros, rampas, chimeneas y tajos en operación dentro de la unidad minera. Para el análisis, se consideraron parámetros como el rendimiento de brocas, barrenos y su vida útil en condiciones de roca dura. Los resultados evidenciaron que el consumo mensual estimado alcanza aproximadamente 800 brocas, 840 barrenos de 6 pies y 1219 barrenos de 4 pies. Asimismo, se determinó una vida útil promedio de 250 pies perforados en promedio para brocas de 36 mm tipo BOART LONGYEAR. Los resultados permitieron concluir que el rendimiento y la vida útil de los aceros de perforación influyen directamente en la estimación del consumo mensual,

constituyéndose en un factor clave para la planificación y control de costos en labores de avance.

Flores & Marinez (2023) realizaron un estudio en la minera aurífera Retamas S.A., enfocado en la importancia de la perforación como operación unitaria clave para lograr una adecuada voladura y fragmentación del macizo rocoso. El estudio identificó como principal problemática la falta de paralelismo en los taladros, la cual se incrementa con la longitud de perforación, generando desviaciones que afectan el rendimiento de las herramientas y la calidad del proceso. Asimismo, se evidenció que estas desviaciones provocan fallas en los equipos de perforación, como el desgaste prematuro de la broca, rotura de insertos, doblamiento o rotura del barreno, lo que repercute negativamente en el avance de la labor, disminuyendo la productividad y generando sobrecostos por voladura secundaria y sostenimiento debido a la sobrerotura. El estudio comparó el rendimiento de herramientas cónicas de perforación (barras y brocas), permitiendo una evaluación situacional en dos escenarios. En el primero, se registró un avance de 90 m lineales y 3,780 m perforados, evidenciándose pérdidas en la vida útil de las herramientas debido a malas prácticas operativas. En el segundo escenario, tras mejorar el control en el emboquillado y el empuje de avance, se alcanzó un avance de 103 m lineales y 4,326 m perforados, logrando incrementar la vida útil de las brocas en 32,60 m y de las barras en 181,50 m por encima de su rendimiento esperado. Los resultados demuestran que el control adecuado de los parámetros operativos en perforación permite mejorar el rendimiento de las herramientas, incrementar el avance y optimizar los costos operativos.

Prieto & Patiño (2024) realizaron una investigación en una unidad minera del Perú, enfocada en la reducción de costos de perforación mediante el uso eficiente de aceros T38 en el método de explotación sublevel stoping. El estudio parte de la importancia

del tren de varillaje, compuesto por aceros de perforación como T38 y T45, los cuales son fundamentales para la ejecución de taladros largos en minería subterránea. El objetivo del estudio fue reducir los costos operativos asociados al consumo de aceros de perforación, para lo cual se propuso la implementación de un procedimiento integral de trabajo orientado a optimizar la perforación con equipos Simba. Inicialmente, se identificó que el costo planeado de perforación era de 1.78 USD/m, siendo este menor en 7.29% respecto al costo real, lo que evidenciaba ineficiencias en la operación. Tras la implementación del nuevo procedimiento, se logró incrementar la vida útil del tren de varillaje, alcanzando un costo promedio final de 1.56 USD/m en las tres zonas de estudio, lo que representa una reducción del 19% respecto al costo real y un 12.4% por debajo del costo planeado. Asimismo, se registró un incremento en la producción de 7234.30 toneladas métricas, debido a la disminución de paradas operativas durante la perforación. Los resultados evidencian que la optimización de los procedimientos de perforación y el control del uso de aceros permiten mejorar la eficiencia operativa, reducir costos y aumentar la productividad en el método sublevel stoping.

Huamani (2023) realizó una investigación en la Compañía Minera Volcan S.A.A. – Andaychagua, enfocada en el análisis de la vida útil de los aceros de perforación y su influencia en la optimización de los costos por metro perforado. El estudio se desarrolló a partir de la observación de las operaciones en diferentes labores y equipos, tales como frontoneros, sostenimiento y taladros largos, considerando información correspondiente al año 2021. La investigación evaluó la relación entre la columna de perforación, los parámetros operativos de los equipos y la supervisión del uso de los aceros, considerando componentes como shank, barras y coupling. Asimismo, se implementaron acciones de control como el monitoreo de parámetros de perforación, seguimiento de la vida útil de los aceros, afilado de brocas y capacitación del personal

en el manejo adecuado de los equipos y en seguridad. Los resultados evidenciaron que una adecuada supervisión y control operativo permiten incrementar la vida útil de los aceros de perforación, lo que se traduce en una optimización de los costos por metro perforado. Se logró mejorar la eficiencia operativa de 90% a 103%, además de generar una valorización económica anual de 254,789.54 dólares, considerando los beneficios obtenidos y la asistencia técnica. Los resultados demuestran que la evaluación integral de la columna de perforación y la gestión adecuada de los aceros contribuyen significativamente a la mejora de la eficiencia y la reducción de costos en las operaciones mineras.

Barrientos (2022) desarrolló una investigación en la Compañía Minera Aruntani – Unidad Santa Rosa, enfocada en el estudio técnico-económico del uso de barras de perforación durante el año 2022. El estudio analizó la relación entre barras nacionales e importadas en términos de rendimiento y vida útil de los aceros de perforación, con el fin de evaluar su impacto en la operación minera. La investigación se realizó bajo el método científico, empleando enfoques deductivos, hipotético-deductivo y analítico. Para la recolección de datos se utilizaron técnicas de investigación documental y de campo, considerando el análisis del consumo y rendimiento de los aceros de perforación en la unidad minera. Los resultados evidenciaron que el análisis técnico-económico influye significativamente en la selección de las barras de perforación. Se determinó que las barras nacionales presentan un mejor desempeño, con un costo de 2500 dólares y una vida útil de 10,000 metros, en comparación con las barras importadas, que tienen un costo de 3500 dólares y una vida útil de 8,000 metros. En consecuencia, el uso de barras nacionales resulta más eficiente, ya que ofrece mejor relación costo-beneficio y cumple con las especificaciones operativas requeridas. Los resultados demuestran que la evaluación técnico-económica es un factor clave para

optimizar la selección de aceros de perforación y reducir costos en las operaciones mineras.

2.1.2 Locales

Quito & Jaramillo (2020) realizaron una investigación en la unidad minera San Cristóbal – Yauli, perteneciente a la Compañía Minera Volcan S.A.A., enfocada en la optimización del uso de aceros de perforación en el método de explotación con taladros largos, específicamente en el nivel 1120, labor SP 6 del tajo 120 E-W. El estudio se desarrolló en una zona con explotación de minerales polimetálicos como zinc, plata, cobre y plomo. La investigación planteó un proceso de optimización basado en el análisis de las condiciones geomecánicas del área con mayores pérdidas, seguido de la identificación de factores y parámetros operativos que afectan el rendimiento de los aceros de perforación. A partir de ello, se estableció un plan de acción orientado a mitigar las causas de pérdidas, incluyendo la evaluación de riesgos y su influencia en el proceso de optimización. Los resultados evidenciaron que la optimización del rendimiento de los aceros de perforación generó beneficios económicos, alcanzando un valor anual de 11,497.98 dólares y un valor mensual de 383.27 dólares en las actividades de preparación y desarrollo con el equipo Boomer S1D. Asimismo, se determinó que la velocidad de perforación depende directamente del estado de la broca, disminuyendo con el desgaste progresivo; en este contexto, el afilado de brocas contribuye a incrementar la vida útil de los aceros de perforación y a optimizar los costos operativos. Los resultados demuestran que el control de parámetros operativos y el mantenimiento adecuado de los aceros permiten mejorar el rendimiento y reducir pérdidas económicas en la perforación con taladros largos.

Chavez (2024) realizó un estudio titulado “Evaluación de pérdidas prematuras y su incidencia en el rendimiento de los accesorios de la columna de perforación en taladros

largos en la UO San Cristóbal, CIA Minera Volcan S.A.A., 2023”. La investigación surge por el elevado consumo de accesorios de la columna de perforación en labores de avance, generando altos costos operativos que podrían afectar la viabilidad de la empresa. El propósito del estudio fue evaluar las pérdidas prematuras para mejorar el rendimiento de los accesorios de la columna de perforación en taladros largos. Se aplicó un enfoque de investigación aplicada y cuasi experimental, utilizando instrumentos como recolección de datos, revisión bibliográfica y fichas de control de campo. Los controles que tuvieron mayor influencia en los resultados incluyeron: control de parámetros de perforación, supervisión del estado del boom de perforación, afilado de brocas y capacitación de operadores. Gracias a estas medidas, se logró optimizar la vida útil de los aceros de la columna de perforación en un 104% para el mes de diciembre. Además, se identificó la importancia de caracterizar el macizo rocoso, lo cual permitió relacionar la resistencia de la roca con la vida útil de los accesorios de perforación. Los resultados obtenidos mostraron lo siguiente:

- Shank Cop1838 T38 D52 L525mm: vida útil de 1734 m
- Shank Cop1838 T38 D38 L435mm: vida útil de 1527 m
- Barra Mf T38 R39 T38 L1525mm (5’): vida útil de 224 m
- Barra Mf T38 R39 T38 L1220mm (4’): vida útil de 220 m
- Broca Retráctil T38 64mm - 9’’: vida útil de 266 m
- Broca Escariadora T38 127mm (5’’) Dom C/Pilot: vida útil de 156 m

Estos resultados indican que la implementación de controles operativos y de mantenimiento mejora significativamente el rendimiento y la eficiencia de los aceros de perforación en taladros largos.

2.2 Bases teóricas

2.2.1 Perforación en minería subterránea

Zhang (2016) Explica que:

La perforación de rocas se utiliza para realizar taladros destinados a la carga de explosivos en voladuras; para la instalación de pernos en el sostenimiento de roca; para la extracción de petróleo, gases de esquisto y gas natural; para la obtención de testigos; para la producción de piedra de construcción; para la ejecución de ranuras que reduzcan las vibraciones; para el drenaje de agua en el macizo rocoso; para el monitoreo de la deformación y fracturamiento del macizo rocoso; y para el almacenamiento de CO₂ en formaciones rocosas subterráneas. (p. 155)

La clasificación de los métodos de penetración en el macizo rocoso se fundamenta en los mecanismos de transferencia de energía y el tipo de sollicitación mecánica aplicada a la roca. Según la literatura técnica (Carlisle, 2023; Famesa Explosivos S.A., 2019; Zhang, 2016), la perforación minera se categoriza predominantemente en dos sistemas: rotopercutivo y rotativo.

1. Sistema de Perforación Rotopercutiva

Este método fundamenta su avance en la combinación de impactos de alta frecuencia y un movimiento de rotación para indexar los insertos de la broca. Se subdivide de acuerdo a la ubicación del mecanismo de impacto:

- **Martillo en Cabeza (Top Hammer):** Empleado típicamente en labores de minería subterránea y bancos de tajo abierto con diámetros inferiores a 150 mm (≈ 6 in). En esta configuración, la energía de impacto se transmite desde la perforadora a través de una sarta de perforación acoplada (barras y

adaptadores de culata o shanks), lo que genera una atenuación de la onda de choque proporcional a la profundidad del taladro.

Figura 4

Perforadora de martillo de cabeza Atlas Copco




Nota. Tomada de Atlas Copco, 2014, p. 67.

- **Martillo de Fondo (DTH - Down-The-Hole):** Diseñado para taladros de mayor diámetro (75 mm a 508 mm). Al posicionar el martillo directamente sobre la broca, se optimiza la eficiencia de transferencia energética, minimizando las pérdidas por reflexión en la sarta y garantizando una mayor linealidad en el barreno.

Figura 5

Perforadora con martillo de fondo Arlas Copco



Nota. Tomada de Zhang, 2016, p. 158.

2. Sistema de perforación rotativa

En este sistema, la fragmentación de la roca se produce mediante la aplicación de una carga axial elevada (pulldown) y un torque constante. La selección de la herramienta de corte es función de la resistencia a la compresión simple (UCS) del material:

- Acción por Corte (Drag Bits): Utilizada en formaciones geológicas de baja competencia (rocas blandas) con diámetros de hasta 250 mm.
- Acción por Trituración (Triconos): Es el estándar para rocas de dureza media a alta en minería superficial (tajos abiertos), empleando brocas de

rodillos de carburo de tungsteno en diámetros que superan los 300 mm (12 in).

Figura 6

Perforación rotativa Atlas Copco



Nota. Tomada de Zhang, 2016, p. 160.


3. Consideraciones sobre tecnologías especializadas

Si bien los métodos mencionados constituyen la base de la producción y el desarrollo, existen tecnologías de perforación de sección completa como las TBM (Tunnel Boring Machines) y el sistema Raise Boring para chimeneas. Aunque operan bajo principios rotativos, su ingeniería se diferencia por el manejo de grandes diámetros y la gestión de detritos (cuttings) a gran escala.

En términos operativos, la eficiencia de estos sistemas depende intrínsecamente de la integridad y selección de los consumibles de la sarta: barras de perforación, brocas de botones, adaptadores de culata y coples, los cuales constituyen los elementos críticos de transferencia de energía en el ciclo de minado.

Figura 7

Distribución de los botones en una broca de perforación



Nota. (a) Los botones y los orificios de barrido (flushing) en la broca durante el primer impacto de percusión; (b) las posiciones de los botones después del primer impacto de percusión, es decir, después de que la broca ha girado un ángulo ϕ . Tomada de Zhang, 2016, p. 172.


2.2.1 Jumbo de perforación

Jimeno et al. (2017) sostiene que la mecanización de la perforación en la minería subterránea y la construcción civil de túneles ha alcanzado un nivel de sofisticación tecnológica que sitúa al jumbo de perforación como el activo más crítico en el ciclo de avance y producción. El término "jumbo" se refiere a una plataforma móvil que integra uno o más brazos hidráulicos equipados con perforadoras de percusión y rotación, diseñadas para ejecutar taladros en el macizo rocoso con una precisión geométrica que los métodos manuales no pueden igualar. Esta maquinaria no solo ha transformado la velocidad de penetración, sino que ha redefinido los estándares de seguridad al distanciar al operador del frente de trabajo, especialmente en zonas de roca no consolidada.

El jumbo de perforación moderno se define como un sistema electrohidráulico complejo cuya función principal es la creación de barrenos para la inserción de explosivos o elementos de sostenimiento. La eficiencia de este equipo se mide por su capacidad para mantener un paralelismo estricto entre los taladros, lo que garantiza una fragmentación homogénea y minimiza la sobreexcavación, factores que impactan directamente en los costos operativos de la mina (Jimeno et al., 2017).

Figura 8

Jumbo Epiroc de dos brazos



Nota. Tomada de Epirco.com

2.2.1.1 Evolución técnica y principios operativos

La transición de la perforación neumática manual a la perforación hidráulica mecanizada representó un salto en la eficiencia energética y la ergonomía. Mientras que los sistemas neumáticos presentaban eficiencias bajas y altos niveles de ruido y polvo, los jumbos hidráulicos operan con sistemas de circuito cerrado que permiten una transferencia de energía superior hacia la roca. La potencia de impacto de una perforadora moderna, expresada matemáticamente, se correlaciona con la frecuencia de impacto y la energía por golpe:

$$P_{\text{impacto}} = E_{\text{golpe}} \cdot f_{\text{impacto}}$$

Donde P es la potencia en vatios, E es la energía por golpe en julios y f es la frecuencia en hercios. En los modelos actuales, esta potencia oscila entre los 16 kW y los 40 kW, permitiendo velocidades de penetración aceptables en rocas de dureza media.

2.2.1.2 Componentes críticos del sistema de perforación

La arquitectura de un jumbo se divide en el chasis o unidad de transporte y la unidad de perforación propiamente dicha. La perforadora de roca, o drifter, es el componente de mayor valor tecnológico; define aproximadamente el 50% del rendimiento del equipo. Estas unidades emplean un pistón accionado hidráulicamente que golpea el adaptador de culata del varillaje, transmitiendo una onda de choque a través del acero de perforación hasta la broca

Tabla 1

Componentes críticos del sistema de perforación

Componente	Descripción y Relevancia Técnica	Modelos de Referencia
Perforadora (Drifter)	Motor de impacto y rotación. Utiliza sistemas de amortiguación doble para proteger el varillaje.	COP 1838+, RD520, HC 95.
Brazo (Boom)	Estructura articulada con múltiples grados de libertad que permite el posicionamiento preciso.	BUT 28, SB40, BUT 45. 4
Viga de Avance (Feed)	Soporte de la perforadora; aplica la fuerza de empuje necesaria para mantener el contacto broca-roca.	BMH 2000, TF500, TFX series.
Unidad de Potencia	Conjunto de motores y bombas hidráulicas. Generalmente dual (diésel para traslado, eléctrico para perforación).	Motores de 45 kW a 158 kW.

La viga de avance, construida frecuentemente en aleaciones de aluminio de alta resistencia para reducir el peso y mejorar la agilidad, incorpora sistemas de alimentación telescópica en modelos diseñados para espacios reducidos, permitiendo el uso de barras de diferentes longitudes en una misma configuración.

2.2.1.3 *Clasificación sistémica de los jumbos de perforación*

La clasificación de los jumbos responde a una necesidad de especialización según la geometría de la labor y el método de explotación. Se pueden categorizar bajo tres ejes principales: función operativa, sistema de propulsión y configuración estructural.

2.2.1.3.1 *Clasificación por función operativa*

1. Jumbos de Avance o Desarrollo (Face Drill Rigs): Optimizados para la excavación de galerías horizontales. Su diseño prioriza la cobertura frontal y el paralelismo automático para asegurar que el avance de la labor siga la dirección proyectada.
2. Jumbos de Producción (Long Hole Rigs): Diseñados para la perforación radial o en abanico. Estos equipos, como la serie Simba de Epiroc o DL de Sandvik, se utilizan en métodos de minado masivo (Sublevel Stopping) donde se requieren taladros de gran longitud (hasta 30-50 metros) con una desviación mínima.
3. Jumbos Empernadores o de Fortificación (Bolting Rigs): Especializados en el sostenimiento mecanizado. Integran una torreta que permite perforar e instalar el perno (Split Set, helicoidal o Swellex) en un solo ciclo, eliminando la necesidad de manipulación manual de los elementos de anclaje.
4. Jumbos Desatadores (Scalers): Aunque su función no es perforar barrenos de voladura, utilizan brazos articulados y martillos hidráulicos para remover rocas sueltas del techo y paredes, siendo esenciales para la seguridad post-voladura.

2.2.1.3.2 *Clasificación por sistema de propulsión y energía*

La fuente de energía define la autonomía y el impacto ambiental del equipo dentro de la mina.

1. Jumbos Electrohidráulicos: Son el estándar actual. Utilizan un motor diésel para el desplazamiento entre labores (tramming) y un motor eléctrico para accionar las bombas hidráulicas durante la perforación, conectándose a la red eléctrica mediante un carrete de cable.
2. Jumbos Diésel-hidráulicos: Totalmente autónomos, operan todas sus funciones mediante un motor de combustión interna. Son preferidos en proyectos de infraestructura civil remota o en minas en fases iniciales de desarrollo donde no existe red eléctrica.
3. Jumbos Eléctricos por Batería (BEV): Representan la tendencia hacia la "minería verde". Eliminan las emisiones de escape, reducen drásticamente la generación de calor y el ruido, lo que optimiza los costos de ventilación en minas profundas.

2.2.1.3.3 *Clasificación por configuración y tamaño de sección*

La sección de la labor es el parámetro geomecánico que determina el tamaño del jumbo.

1. Micro Jumbos y Perfil Bajo: Diseñados para vetas angostas y mantos con alturas de hasta 1.3 metros. Modelos como el Muki de Resemin o el Boomer S1 L de Epiroc son ejemplos de ingeniería compacta para minería selectiva.
2. Jumbos de Sección Mediana: Equipos de uno o dos brazos para túneles de 12 m² a 45 m². El Boomer 282 es la referencia histórica en esta categoría.

3. Jumbos de Gran Sección: Unidades con tres o cuatro brazos, capaces de cubrir áreas de hasta 206 m². Se utilizan en túneles carreteros, ferroviarios o cavernas de centrales hidroeléctricas.

2.2.1.3.4 Clasificación por marcas y modelos líderes

El mercado global está dominado por tres fabricantes principales que establecen las pautas tecnológicas, seguidos por empresas especializadas en nichos específicos.

Fabricante: Epiroc (Series Boomer y Simba)

Epiroc ha enfocado su desarrollo en el sistema de control RCS (Rig Control System), que permite niveles de automatización desde lo básico hasta la operación telerremota total.

Tabla 2

Modelos más representativos de Epiroc

Modelo	Tipo	Cobertura / Rango	Especificaciones Clave
Boomer S1 L	Avance	Hasta 29 m ²	Perfil bajo (1.3 m altura), brazo BUT 28, perforadora COP.
Boomer 282	Avance	12 a 45 m ²	Doble brazo BUT 28, control hidráulico directo (DCS), robustez probada.
Boomer M20	Avance	Hasta 65 m ²	Perforadoras COP MD20, mangueras internas, alta visibilidad, sistema digital.
Boomer XE3	Avance	Hasta 206 m ²	Tres brazos BUT 45L, diseñado para grandes proyectos de tunelería civil.
Simba 1254	Producción	Radial / Pequeña	Compacto, diseñado para galerías de dimensiones reducidas.
Simba 1354	Producción	Radial / Mediana	Brazo pendular, mecanización hasta 32 m de profundidad, perforadora COP 1838+.
Simba E70 S	Producción	Radial / Grande	Automatización avanzada, precisión en barrenos largos, integración con software de mina.

Nota. Elaboración propia.

La serie Boomer destaca por su versatilidad, permitiendo la instalación de accesorios como el sistema de manejo de barras (RHS) para perforación de drenaje o inyección de lechada (grouting).

Fabricante: Sandvik (Series DD y DL)

Sandvik prioriza el rendimiento de sus perforadoras de la serie RD y RDX, junto con la plataforma digital i-Class que ofrece una interfaz intuitiva y diagnósticos avanzados.

Tabla 3

Modelos más representativos de Sandvik

Modelo	Tipo	Cobertura / Rango	Especificaciones Clave
DD210	Avance	Secciones estrechas	Compacto, diseñado para minería de vetas con radios de giro reducidos.
DD311	Avance	Hasta 40 m ²	Un solo brazo SB40, perforadora RDX5 de 20 kW, paralelismo automático.
DD321	Avance	Hasta 49 m ²	Doble brazo SB40, motor diésel Cummins 124 kW, cabina FOPS/ROPS ergonómica.
DD422iE	Avance	Secciones medianas	Accionamiento eléctrico por batería, carga regenerativa en descenso, cero emisiones locales.
DL321	Producción	Galerías 3.2 x 3.2 m	Perforadora HL820ST, carrusel de 20+1 barras, cobertura de 360°.
DL422i	Producción	Galerías 4.0 x 3.5 m	Automatización i-Class, taladros de 64-102 mm, longitud hasta 54 m.
DU311	Producción	ITH (In the Hole)	Especializado en martillo de fondo, taladros verticales de hasta 100 m.

Nota. Elaboración propia.

La ingeniería de Sandvik en el modelo DD320S y su sucesor DD321 ha mejorado la facilidad de mantenimiento al centralizar los puntos de servicio y reducir la cantidad de mangueras expuestas en los brazos.

Fabricante: Resemin (Enfoque en Vetangostas)

Resemin, de origen peruano, se ha posicionado globalmente como el líder en el segmento de equipos para minería selectiva, ofreciendo soluciones donde los jumbos convencionales no pueden operar por restricciones geométricas.

Tabla 4*Modelos más representativos de Resemin*

Modelo	Tipo	Rango de Sección	Especificaciones Clave
Muki FF Troidon	Avance	2.5 x 2.5 m	El más pequeño de su clase, perforadora Montabert HC 50 de 14 kW.
Troidon 44	Avance	2.5 a 4.5 m	Brazo de paralelismo automático, perforadora Montabert HC 95LMA de 22 kW.
Troidon 66 XP	Avance	3.5 a 5.3 m	Diseñado para alta velocidad de avance en secciones medianas, sistema anti-atascamiento.
Muki 22	Producción	Secciones mínimas	Desmontable para transporte por chimeneas, brazo pendular, taladros hasta 15 m.
Raptor 44 XP	Producción	Secciones pequeñas	Brazo 4AP con paralelismo automático, perforadora Montabert HC 95 de 24 kW.
Muki Bolter	Pernado	2.5 x 2.7 m	Torreta T99 para pernos Swellex o Split Set, diseño simple sin sensores complejos.

Nota. Elaboración propia.


La propuesta de valor de Resemin radica en la simplicidad mecánica ("diseño simple, fácil de operar") que facilita el mantenimiento en minas con logística complicada.

2.2.2 Columna de perforación

La columna de perforación en jumbos de avance es un sistema dinámico complejo que debe soportar esfuerzos mecánicos extremos, incluyendo compresión, tensión, torsión y flexión cíclica. En las operaciones modernas, estos componentes son sometidos a frecuencias de percusión que oscilan entre los 40 y los 93 Hz, lo que implica que la sarta recibe hasta 5,580 impactos por minuto. La capacidad de la columna para gestionar estas cargas determina no solo la velocidad de penetración (ROP), sino también la integridad estructural del martillo hidráulico, ya que una mala transmisión de energía resulta en ondas reflejadas que pueden dañar los componentes internos de la perforadora.

Figura 9

Columna de perforación en frentes



Nota. Tomado de Boart Longyear, 2018.

Principios de propagación de ondas de tensión

El funcionamiento de la columna se basa en la teoría de la propagación de ondas unidimensionales en barras elásticas. Cuando el pistón del martillo golpea el adaptador de culata (shank), se genera una onda de compresión que viaja a través del acero a una velocidad aproximada de $c = 5.100 \text{ m/s}$. La magnitud de esta tensión σ está dada por la relación entre el módulo de Young del acero E , la densidad del material ρ y la velocidad de la partícula v , expresada matemáticamente como $\sigma = \rho \cdot c \cdot v$.

En cada interfaz de la columna, particularmente en las uniones roscadas mediadas por coupling o en las conexiones MF (Male-Female), se produce una discontinuidad de impedancia mecánica. Si las superficies de contacto no están perfectamente acopladas, una fracción de la onda de choque se refleja hacia atrás en forma de onda de tensión, reduciendo la energía disponible para la fracturación de la roca en la broca. Los sistemas de rosca avanzados, como el Alpha 360 o el Magnum SR, han sido diseñados específicamente para maximizar el área de contacto y minimizar estas pérdidas por reflexión, logrando una transferencia de energía superior al 90%.

Variables operacionales y su impacto en la sarta

La columna de perforación debe ser seleccionada en función de los parámetros del martillo y las características del macizo rocoso. En jumbos de avance, las potencias de impacto varían significativamente, lo que dicta el diámetro y la robustez de la columna necesaria para evitar fallas prematuras por fatiga.

Tabla 5

Parámetros del martillo

Modelo de Perforadora	Potencia de Impacto (kW)	Frecuencia (Hz)	Diámetro de Columna Recomendado
Sandvik RD520	20 kW	70-80 Hz	R32 - T38
Sandvik RD525	25 kW	93 Hz	T38 - Alpha 330
Sandvik RD535	31 kW	>90 Hz	GT38 - Alpha 360
Epiroc COP 1838	18-20 kW	60-90 Hz	R32 - T38
Epiroc COP 4038	40 kW	Alta	ST68 - Sistemas ET

Nota. Elaboración propia.

La interacción entre el empuje (feed force) y la rotación es igualmente vital. Un empuje insuficiente provoca que la columna "baile" dentro del barreno, generando impactos en vacío que fracturan los acoplamientos, mientras que un empuje excesivo incrementa el par de rotación y puede causar desviaciones severas o atascos (stuck drilling). La precisión en la perforación es el factor que más influye en el costo por metro de avance, ya que desviaciones mayores al 2% resultan en un incremento del 13% en los costos operativos debido a la fragmentación deficiente y al daño al contorno del túnel.


2.2.2.1 Broca

La broca es el componente terminal de la columna y el único que entra en contacto directo con la roca para realizar el trabajo de fragmentación. En los jumbos de avance, el diseño predominante es la broca de botones (button bit), la cual utiliza insertos de carburo de tungsteno para triturar la roca mediante impactos sucesivos combinados con una rotación lenta.

Las brocas rotopercutivas se emplean en sistemas de perforación que integran movimientos de rotación y percusión con el fin de fragmentar rocas de alta dureza. Este tipo de herramienta es ampliamente utilizado en equipos como los martillos en cabeza (top hammer) y los martillos de fondo (DTH). Su diseño está preparado para resistir elevadas cargas de impacto y condiciones severas de desgaste, incorporando generalmente insertos de materiales muy duros, como el carburo de tungsteno. Se clasifican principalmente en brocas de botones y brocas de placas, además de incluir variantes especializadas como las brocas de escarpado.

Figura 10


Partes de la broca rotopercutiva



Nota. Tomado de Boart Longyear, 2018.

Figura 11

Mecanismo de fragmentación de broca de perforación



Nota. Tomada de Kwon et al., 2014.

Tabla 6

Tipos de botones.

Tipo de botones		
Botón hemisférico	Ideal para suelo duro	
	25,000 a 45,000 PSI (170 a 300 MPa)	
	Abrasivo a muy abrasivo	
Botón parabólico (semi balístico)	Penetración rápida	
	Ideal para suelo mediano	
	15,000 a 25,000 PSI (100 a 170 MPa)	
Botón cónico	Suelo ligeramente abrasivo	
	Intensidad de la aplicación: penetración rápida	
	Adecuado para todos los tipos de suelo no abrasivos	
	Área de contacto más pequeña	
Botón balístico	Ideal para brocas de menor diámetro	
	Penetración rápida	
	Adecuado para todos los tipos de suelo no abrasivos	
	Área de contacto más pequeña	
	Ideal para brocas de menor diámetro	

Nota. Tomado de Boart Longyear, 2018, p. 9.

Figura 12


Tipos de caras de brocas a botones



Nota. Tomada de Boart Longyear, 2018, p. 9.

Figura 13

Relación de la abrasividad y el tipo de broca



Nota. Elaboración propia.

2.2.2.2 Barra

La barra de perforación es el elemento longitudinal que define la profundidad de la voladura en el avance frontal. En los jumbos, estas barras deben poseer una combinación paradójica de rigidez para mantener la rectitud y elasticidad para absorber las ondas de flexión.


Secciones y configuraciones geométricas

Tradicionalmente, las barras para jumbos se fabrican en dos geometrías de sección transversal:

- Barras Hexagonales (H): Son predominantes en la perforación de túneles debido a su mayor área de sección transversal respecto a su peso, lo que les otorga una resistencia superior a la flexión. Además, las aristas del hexágono ayudan en la limpieza del barreno al actuar como un transportador de detritos en espacios anulares pequeños.
- Barras Redondas (R): Se utilizan principalmente en aplicaciones de perforación de extensión o cuando se requieren diámetros de barreno mayores a 51 mm, ofreciendo una menor resistencia al flujo de barrido externo.
- Las barras MF (Macho-Hembra): Son varillas de acero fabricadas para usar en perforaciones mineras y con martillos de cabeza. Expresar de otro modo Tienen una rosca macho en un extremo y una rosca hembra en el otro. Este diseño le da más firmeza a la cadena, permite hacer agujeros más derechos, reduce la pérdida de fuerza y mejora el tiempo para cambiar las herramientas en equipos como jumbos de perforación.

Figura 14

Tipos de hilos de barra en rosca



Nota. Tipos de hilos de barra en forma de “T” y “R”. Tomada de Boart Longyear, 2018, p. 9.

Figura 15

Barras hexagonales



Nota. Barra hexagonal para brocas cónicas. Tomada de Atlas Copco, 2014, p. 120.

2.2.2.3 *Coupling*

El manguito de acoplamiento o coupling es el cilindro de unión roscado que conecta el shank con la barra o dos barras consecutivas. Aunque parece un componente simple, su diseño es fundamental para la alineación coaxial de la columna, factor determinante en la transmisión eficiente de la onda de choque.

Mecánica de contacto y tipos de manguito

El coupling debe asegurar que los extremos de los componentes que une se toquen físicamente (contacto metal-metal), permitiendo que la onda de choque pase a través de las caras de impacto y no solo a través de los hilos de la rosca.

1. Manguitos de Semipunte (Semi-bridge): Son el estándar para jumbos de avance. Poseen una sección central no roscada que garantiza que las dos barras queden centradas y apretadas uniformemente.
2. Manguitos de Puente Completo (Full-bridge): Utilizados en perforaciones que requieren una rigidez extrema, evitando cualquier posibilidad de solapamiento de roscas.

La eficiencia energética es crítica en este punto; se estima que cada unión roscada mal ajustada o con desgaste excesivo puede disipar hasta un 10% de la energía de impacto en forma de calor. Esto no solo ralentiza la perforación, sino que provoca la dilatación térmica del acero, dificultando el desacoplamiento de la sarta al finalizar el barreno.

Figura 16

Manguito de acoplamiento o coupling



Nota. tomada de Boart Longyear, 2018, p. 9.

2.2.2.4 Shank

El adaptador de culata o shank es el primer elemento de la columna de perforación y actúa como la interfaz mecánica directa con el martillo hidráulico. Es probablemente la pieza con los requerimientos metalúrgicos más exigentes, ya que recibe el impacto directo del pistón en un extremo y el torque de rotación a través de sus estrías laterales.

Funciones técnicas y transferencia de energía

El shank debe cumplir tres funciones simultáneas sin fallar:

- Transmisión de impacto: Recibe el golpe del pistón y genera la onda de tensión inicial. La cara de impacto del shank debe estar perfectamente perpendicular al eje para evitar cargas excéntricas que dañarían el pistón.
- Transmisión de rotación: Mediante un conjunto de estrías (splines) mecanizadas con precisión CNC, el shank se acopla a la caja de rotación de la perforadora. Debe transmitir torques que superan los 400 Nm en condiciones de roca difícil.

- Gestión del fluido de barrido: Posee un canal interno y zonas de sellado mediante empaquetaduras (shanks seals) que permiten la inyección de agua a alta presión hacia el interior de la sarta.

Configuración del shank según el martillo

Los shanks se diseñan específicamente para cada modelo de perforadora, variando en longitud, número de estrías y diámetro.

Tabla 7

Configuración del shank

Marca/Modelo de Martillo	Tipo de Shank	Características de Diseño
Sandvik RD525	Shank R38/T38	Diseñado para alta frecuencia, cara de impacto reforzada
Epiroc COP 1838	Shank R32/T38	Sistema de lubricación por aire-aceite integrado
Montabert HC150	Shank T45	Estrías sobredimensionadas para alto torque

Nota. Elaboración propia.

El mantenimiento del shank es vital; un desgaste de apenas unos milímetros en la cara de impacto puede alterar la sincronización del martillo, provocando un fenómeno conocido como "impacto en vacío interno", que es la causa principal de fallas en las culatas y pistones de las perforadoras hidráulicas.

Figura 17

Shank y sus diferentes configuraciones



Nota. Tomada de Boart Longyear, 2018, p. 9.

2.2.3 Vida útil de herramientas de perforación

La vida útil de los aceros de perforación es el tiempo, distancia (metros) o número de taladros que una herramienta de perforación (brocas, barras) puede funcionar eficazmente antes de requerir afilado, reparación o descarte por desgaste. Se mide en metros perforados, minutos de uso o número de taladros, siendo el desgaste del flanco el principal criterio.

2.2.4 Parámetros de perforación

2.2.4.1 Parámetros operativos

Los parámetros operativos constituyen el conjunto de variables ajustables que definen el rendimiento del martillo hidráulico y la sarta de perforación o columna de perforación en contacto con el frente de roca. Estos parámetros, presión de percusión, presión de avance, velocidad de rotación y presión de barrido, actúan de manera interdependiente, donde la alteración de uno afecta inevitablemente el comportamiento de los demás y la integridad física de los componentes de acero(Guo et al., 2024).

2.2.4.1.1 Presión de percusión

La presión de percusión es la variable determinante en la fragmentación de la roca dentro del sistema de perforación rotopercutiva. Este parámetro controla la energía cinética que un pistón hidráulico, ubicado dentro del martillo, transfiere a través del culatín (shank) y las barras hasta llegar a la broca. La energía de impacto se desplaza como una onda de choque compresiva a una velocidad aproximada de 5,000 m/s a través del acero de perforación. Al alcanzar la interfaz entre los botones de carburo de tungsteno y la roca, la energía supera la resistencia a la compresión del material pétreo, generando una zona de trituración y microfisuramiento que permite el avance del barreno.

El ajuste de la presión de percusión es crítico para el control del desgaste. Una presión excesiva en rocas de baja competencia geomecánica provoca que la energía no sea absorbida totalmente por el frente, generando ondas de choque reflejadas (ondas de tensión) que regresan a través de la columna de perforación. Este fenómeno, conocido como "percusión en vacío", es una de las causas principales de la fatiga metálica acelerada, provocando la rotura de las roscas, el sobrecalentamiento de los acoplamientos y el desgaste prematuro de los sellos del martillo. En equipos modernos como el COP 1838ME de Epiroc, la presión de percusión en perforación plena suele regularse entre los 170 y 200 bar, dependiendo estrictamente de la dureza de la roca expresada en MPa.

Tabla 8

Presión de percusión

Condición de percusión	Consecuencia en el acero de perforación	Efecto en el rendimiento operativo
Presión Excesiva	Microfisuras en botones y fractura de varillas por fatiga.	Aumento inicial de TDP, pero alta desviación del barreno.
Presión Insuficiente	Desgaste abrasivo excesivo por falta de impacto neto.	Baja tasa de penetración y aumento del costo por metro.
Percusión en Vacío	Reflexión de energía, rotura de culatines y sobrecalentamiento.	Riesgo de daños estructurales graves en el martillo hidráulico.

Nota. Elaboración propia.

2.2.4.1.2 Presión de avance

La presión de avance, o fuerza de empuje, es la encargada de mantener la broca en contacto constante y firme con el fondo del taladro durante el proceso de impacto y rotación. Su función principal es asegurar que la energía de percusión se transmita de forma eficiente a la roca, evitando el rebote de la sarta de perforación. En términos mecánicos, la presión de avance debe ser suficiente para compensar la fuerza de

reacción generada por la percusión, pero no tan alta como para inducir esfuerzos de flexión en las varillas.

El desgaste de los aceros está íntimamente ligado a la precisión de esta presión. Una fuerza de avance insuficiente genera un acoplamiento deficiente entre el martillo y la roca, lo que provoca vibraciones armónicas que dañan las roscas y aceleran el desgaste de los botones por impactos secundarios descontrolados. Por el contrario, una presión de avance excesiva incrementa drásticamente el torque de rotación necesario, lo que se traduce en un desgaste abrasivo acelerado del diámetro exterior de la broca (pérdida de calibre) y un riesgo inminente de atascamiento de la columna de aceros por desviación. Las especificaciones técnicas para equipos Atlas Copco sugieren rangos de 65 a 110 bar, mientras que para equipos Tamrock se recomiendan presiones de 40 a 70 bar, lo que evidencia la necesidad de ajustar el equipo según las directrices del fabricante y la litología local.

2.2.4.1.3 *Velocidad de rotación*

La rotación tiene como objetivo primordial el reposicionamiento de los botones de la broca después de cada impacto de percusión. Esto asegura que el siguiente golpe ocurra sobre una superficie de roca intacta, optimizando la creación de una malla de fracturación circular en el fondo del barreno. La velocidad de rotación, medida en revoluciones por minuto (RPM), debe estar perfectamente sincronizada con la frecuencia de impactos del martillo hidráulico; de lo contrario, se produce una ineficiencia en la fragmentación.

El impacto de la rotación en el desgaste de los aceros es predominantemente abrasivo. Una velocidad de rotación excesiva en formaciones rocosas duras y abrasivas provoca el "pulido" de los botones de carburo, reduciendo su capacidad de penetración y generando un calor excesivo que puede degradar la matriz de acero de la broca.

Además, si la rotación es demasiado alta, se incrementa el par de torsión sobre las varillas, facilitando su rotura por cizallamiento en las zonas de unión. En contraste, una velocidad de rotación muy baja provoca que los botones golpeen repetidamente el mismo punto o que la broca intente "atornillarse" en las fracturas de la roca, lo que aumenta las vibraciones y el riesgo de atascamiento. Para diámetros inferiores a 89 mm, las velocidades operativas suelen oscilar entre 40 y 60 RPM, con ángulos de giro entre 5° y 7° por impacto.

2.2.4.1.4 *Presión de agua y barrido*

El sistema de barrido, que utiliza agua o una mezcla de aire y agua, cumple funciones críticas para la longevidad de los aceros de perforación: la evacuación del detritus de perforación, la refrigeración de la broca y la lubricación de la interfaz de corte. La presión del agua debe ser lo suficientemente alta para transportar los recortes de roca desde el fondo del taladro hasta el exterior a través del espacio anular, evitando que las partículas actúen como un agente abrasivo adicional sobre las varillas y la broca.

El efecto refrigerante del agua es vital para mantener la temperatura del tren de aceros entre los 50 °C y 70 °C. Si la presión de agua cae por debajo de los niveles críticos (generalmente un mínimo de 10 bar), el calor generado por la fricción y la percusión puede provocar un templado no deseado del acero, alterando sus propiedades mecánicas y facilitando fracturas frágiles. Asimismo, un barrido deficiente obliga a la broca a remoler el detritus ya fragmentado, lo que desperdicia energía, reduce drásticamente la velocidad de penetración y causa un desgaste severo en el cuerpo de la broca. Se estima que trabajar con agua reduce el rendimiento de perforación neto en un 10% a 20%, pero es una inversión necesaria para proteger la

vida útil de los aceros y cumplir con las normativas de salud ocupacional al mitigar el polvo respirable.

2.2.4.2 *Parámetros geomecánicos*

Yenice (2019) explica que la eficiencia de un Jumbo de avance no depende exclusivamente de sus capacidades mecánicas, sino de su interacción con el macizo rocoso. Los parámetros geomecánicos definen la resistencia del terreno ante el esfuerzo de corte y su estabilidad durante y después de la perforación. La clasificación geomecánica proporciona un marco cuantitativo para predecir la facilidad con la que una roca puede ser perforada, propiedad denominada perforabilidad.

2.2.4.2.1 *Clasificación Geomecánica RMR (Rock Mass Rating)*

Osinergmin (2017) indica que el sistema RMR, propuesto originalmente por Bieniawski en 1973 y actualizado en 1989, es el estándar más utilizado para la caracterización de macizos rocosos en minería y túneles. Este índice se basa en la suma de puntuaciones asignadas a seis parámetros clave: resistencia a la compresión simple de la roca intacta (UCS), designación de la calidad de la roca (RQD), espaciamiento de las discontinuidades, condición de las discontinuidades, presencia de agua subterránea y orientación de las discontinuidades respecto a la excavación.

El índice RMR resultante varía de 0 a 100 y clasifica el macizo en cinco categorías principales, desde "muy buena" hasta "muy mala". Esta clasificación es fundamental para el diseño del sostenimiento, pero también actúa como un indicador indirecto de la estabilidad del taladro. Por ejemplo, un macizo con un RMR muy bajo (Clase V) presenta un riesgo elevado de colapso de los taladros antes de que puedan ser cargados con explosivos, lo que requiere un ajuste en los tiempos de perforación y, potencialmente, el uso de varillas de perforación con revestimiento o técnicas de consolidación previa.

Tabla 9*Clasificación de macizo rocoso mediante RMR*

Clase de Macizo	RMR	Calidad de la Roca	Implicaciones en la Perforación
I	81 - 100	Muy Buena	Alta resistencia, bajo riesgo de atascamiento, requiere alta percusión.
II	61 - 80	Buena	Condiciones ideales, perforación estable y predecible.
III	41 - 60	Regular	Presencia moderada de fracturas, requiere monitoreo de presión de avance.
IV	21 - 40	Mala	Alta fracturación, riesgo de atascamiento y pérdida de energía en juntas.
V	< 20	Muy Mala	Inestabilidad extrema, colapso de barrenos, difícil evacuación de detritus.

Nota. Adaptada de Osinergmin, 2017.

2.2.4.2.2 Relación entre Geomecánica y Perforabilidad (DRI)

La perforabilidad es un concepto complejo que integra la dureza, la abrasividad y la tenacidad del macizo rocoso. El índice de tasa de perforación (DRI - Drilling Rate Index), desarrollado por NTNU/SINTEF, es la métrica de referencia para cuantificar esta propiedad (Aligholi et al., 2017). El DRI se deriva de dos ensayos de laboratorio: el ensayo de fragilidad S20 y el ensayo de micro-perforación de Sievers' J (SJ) (Capik et al., 2017).

Karrari et al. (2022) explican que existe una correlación significativa, aunque no siempre lineal, entre el índice RMR y la perforabilidad. En rocas con un RMR alto (macizos masivos y competentes), la perforación es más lenta debido a la alta resistencia a la compresión simple (UCS), pero el proceso es mecánicamente estable. Por el contrario, en tramos con RMR inferior a 30, la velocidad de penetración (ROP) suele aumentar considerablemente debido a que la fracturación natural ayuda a la fragmentación iniciada por la broca; sin embargo, esto conlleva un riesgo mayor de desviación de los barrenos y de rotura de los aceros debido a la heterogeneidad del frente. Estudios indican que la perforabilidad está más correlacionada con las

propiedades mecánicas (UCS, BTS) que con las físicas, y que el DRI tiende a disminuir a medida que aumenta la resistencia a la compresión uniaxial y la dureza Schmidt.

2.2.4.3 Parámetros geométricos

La configuración geométrica de los taladros en el frente de avance define la efectividad de la voladura y el éxito del avance lineal. Estos parámetros diámetro de la broca, profundidad del taladro y longitud de la barra de avance están condicionados por las especificaciones técnicas del Jumbo y las dimensiones de la labor minera.

2.2.4.3.1 Diámetro de Broca

El diámetro de la broca determina el volumen de roca que debe ser removido en cada barreno y es un factor crítico en el cálculo del factor de carga (cantidad de explosivo por metro cúbico). En operaciones de avance con Jumbo, se utilizan generalmente dos tipos de diámetros:

- Taladros de producción (producción y contorno): Con diámetros que oscilan típicamente entre 45 mm y 51 mm. Estos taladros albergan la carga explosiva principal.
- Taladros de alivio (arranque): Con diámetros mayores, de 89 mm a 102 mm. Estos taladros no se cargan con explosivo y sirven para proporcionar una cara libre inicial que facilite la expansión de la roca fragmentada.

La selección del diámetro influye directamente en la velocidad de perforación. Para una fuerza de percusión constante, un aumento en el diámetro del taladro reduce la tasa de penetración, ya que la energía de impacto se distribuye sobre un área mayor. Además, el diámetro de la broca debe ser compatible con el tamaño de las varillas de perforación para asegurar un espacio anular óptimo que permita un barrido eficiente del detritus.

2.2.4.3.2 Profundidad del taladro y avance lineal

La profundidad del taladro es la distancia real que la broca penetra en el macizo rocoso. En la perforación de avance, esta profundidad está intrínsecamente ligada a la longitud de la varilla de perforación y a la eficiencia del disparo. El avance lineal, que es la longitud real de túnel ganado tras la voladura, suele ser un 90% a 95% de la profundidad perforada debido a los errores inherentes de paralelismo y a la presencia de la "zapatera" en el fondo del frente.

Un factor geométrico fundamental es que la profundidad del taladro no puede exceder la capacidad física de la viga de avance. En la práctica, se deja un margen de seguridad para evitar que el martillo hidráulico golpee el centralizador o el extremo de la viga. La optimización de la profundidad es vital: taladros más profundos reducen el número de ciclos de perforación necesarios por kilómetro de túnel, pero incrementan exponencialmente el riesgo de desviación, lo que puede causar una fragmentación deficiente y daños a las paredes del túnel (sobre-quiebre).

2.2.5 Modelos de regresión

Young (2018) sostiene que el análisis de regresión es un conjunto de técnicas utilizadas para explorar la relación entre al menos dos variables; es decir, al menos una variable independiente y una variable dependiente.

Los análisis estadísticos se utilizan para hacer generalizaciones sobre poblaciones a partir de la información contenida en una muestra.

2.2.5.1 Regresión lineal simple

Una ecuación de regresión describe cómo el valor medio de una variable y (también llamada variable respuesta o dependiente) se relaciona con valores específicos de la(s) variable(s) x (también llamadas variables predictoras o independientes) utilizadas para

predecir y (Young, 2018). Un modelo de regresión también incorpora una medida de incertidumbre o error. Una forma general de un modelo de regresión es:

valor individual de y = ecuación del promedio + desviación individual respecto al promedio

Supongamos que $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ son realizaciones de los pares de variables aleatorias $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$. La ecuación de regresión lineal simple establece que la media de Y es una función lineal de x . Esto se puede escribir como:

$$E(Y_i) = \beta_0 + \beta_1 x_i$$

donde $E(Y_i)$ representa el valor esperado (media) y el subíndice i denota la i -ésima unidad (hipotética) de la población.

De forma más rigurosa, la ecuación debería escribirse como la media de una variable aleatoria condicional:

$$E(Y_i | X_i = x_i) = \beta_0 + \beta_1 x_i$$

2.2.5.2 Regresión lineal múltiple

Un modelo de regresión lineal múltiple es un modelo lineal que describe cómo una variable de respuesta se relaciona con dos o más variables predictoras o transformaciones de estas variables (Young, 2018).

El modelo poblacional de regresión lineal múltiple que relaciona una variable de respuesta Y con $p - 1$ variables predictoras $X_1, X_2, \dots, X_{p-1}$ se escribe como:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_{p-1} X_{p-1} + \epsilon$$

Sea $(x_{1,1}, \dots, x_{1,p-1}, y_1), \dots, (x_{n,1}, \dots, x_{n,p-1}, y_n)$ las realizaciones de las p variables para una muestra de tamaño n . Entonces, el modelo de regresión lineal múltiple se expresa como:

$$y_i = \beta_0 + \beta_1 x_{i,1} + \beta_2 x_{i,2} + \dots + \beta_{p-1} x_{i,p-1} + \epsilon_i$$

Se asume que los errores ϵ_i son independientes e idénticamente distribuidos, siguiendo una distribución normal $\mathcal{N}(0, \sigma^2)$. Este es el mismo supuesto que en la regresión lineal simple.

El subíndice i hace referencia al i -ésimo individuo o unidad de la población. En la notación de cada predictor, el subíndice posterior a i indica la variable predictora.

2.3 Generalidades de la unidad minera

La Unidad Minera San Cristóbal, ubicada en el distrito de Yauli (Junín, Perú), tiene sus orígenes en la época colonial, cuando los españoles exploraron la zona en busca de metales preciosos, dejando vestigios como la cruz de Rumicruz que dio nombre al lugar en honor a su santo patrón. En el siglo XX, las minas de San Cristóbal y Andaychagua fueron adquiridas en 1935 por la Cerro de Pasco Corporation, que en 1937 descubrió mineralización polimetálica y construyó la planta concentradora Mahr Túnel (operativa desde 1938). En 1965 se identificó la veta de tungsteno, lo que llevó a la construcción de una segunda planta en 1967. Tras la estatización en 1974 bajo el gobierno de Velasco Alvarado, las operaciones pasaron a Centromin Perú. En 1997, Volcan Compañía Minera S.A. adquirió en subasta pública la Empresa Minera Mahr Túnel S.A. (propietaria de San Cristóbal y Andaychagua) por aproximadamente US\$ 128 millones más un compromiso de inversión, fusionándose posteriormente para formar Volcan Compañía Minera S.A.A. Desde entonces, San Cristóbal ha operado como mina subterránea polimetálica (zinc, plomo y plata) dentro del clúster norte de la Unidad Operativa Yauli, con integraciones recientes como la de Carahuacra (desde 2023) y proyectos de exploración e inversión orientados a extender su vida útil.

Figura 18

Mina San Cristóbal



Nota. Elaboración propia.

2.3.1 Ubicación

La Unidad Minera San Cristóbal de Volcan Compañía Minera S.A.A. se encuentra ubicada en la parte suroeste del distrito de Yauli, provincia de Yauli, departamento de Junín, en la sierra central del Perú. Se sitúa aproximadamente a 170 km al este de Lima y a 40 km de la ciudad de La Oroya, con altitudes que oscilan entre los 4.000 y 4.900 metros sobre el nivel del mar. Sus coordenadas geográficas aproximadas son 11°43'00" Latitud Sur y 76°05'00" Longitud Oeste (Zona UTM 18L). El acceso principal se realiza a través de la Carretera Central.

Figura 19

Mapa de ubicación nacional de la Mina San Cristóbal



Nota. Tomada de Espinoza, 2018, p. 44.

2.3.2 Accesibilidad


La Unidad Minera San Cristóbal se localiza en el distrito de Yauli, provincia de Yauli, departamento de Junín, y presenta una accesibilidad favorable dentro de la sierra central del Perú. Se encuentra a aproximadamente 170 km al este de la ciudad de Lima y a 40 km de la ciudad de La Oroya, lo que permite un fácil acceso tanto por vía terrestre como ferroviaria. El acceso principal se realiza a través de la Carretera Central (asfaltada), desde donde, cerca de la localidad de Pachachaca, se desprende un ramal de aproximadamente 18-20 km de carretera afirmada que conduce directamente a la mina y al campamento San Cristóbal. Adicionalmente, cuenta con conexión al Ferrocarril Central, con estación en Yauli a unos 12 km del área de operaciones. El campamento minero se sitúa entre los 4.000 y 4.900 msnm.

Mapa de ubicación de la Mina San Cristóbal



Figura 21

Plano de accesibilidad en la Mina San Cristóbal



Nota. Tomada de Espinoza, 2018, p. 46.

2.3.3 Geología

La geología de la Unidad Minera San Cristóbal se enmarca dentro del Domo de Yauli, una importante estructura anticlinal en los Andes centrales del Perú que expone rocas paleozoicas en una ventana tectónica rodeada de secuencias mesozoicas. Esta configuración regional favorece la presencia de depósitos polimetálicos cordilleranos, caracterizados por vetas y cuerpos de reemplazamiento de zinc, plomo, plata y cobre. La mineralización está asociada a intrusivos porfiríticos y a un sistema hidrotermal que genera zonación metálica marcada.

2.3.3.1 Geología regional

El distrito minero de San Cristóbal se localiza en la parte suroeste del Complejo Domal de Yauli, una amplia estructura domática que abarca los distritos de San Cristóbal y Morococha. Esta estructura representa una ventana tectónica de formaciones paleozoicas dentro de la faja intra-cordillerana de rocas mesozoicas. El buzamiento paleozoico está constituido por dos pisos principales: el Grupo Excélsior (Silúrico-Devónico), que aflora en los anticlinales de Chumpe (oeste) y Ultimátum (este), y el Grupo Mitú (Pérmico), compuesto por rocas volcánicas y piroclásticas andesíticas que dominan el domo. Los márgenes del domo están formados por sedimentos mesozoicos, principalmente el Grupo Pucará (Triásico-Jurásico), Grupo Goyllarisquizga (Cretácico inferior), Grupo Machay y Formación Jumasha (Cretácico medio-superior). La actividad ígnea está evidenciada por stocks y cuerpos intrusivos porfiríticos de composición cuarzo-monzonítica.

2.3.3.2 Geología estructural

La estructura principal del distrito es el anticlinal de Chumpe, de tendencia noroeste, que forma parte del anticlinorio del Domo de Yauli. Este plegamiento expone filitas del Grupo Excélsior en su núcleo y está afectado por un sistema de fracturas y

fallas generadas principalmente durante la fase Quechua. Las vetas principales siguen direcciones preferentes NW-SE y NE-SW, con movimientos normales y desplazamientos significativos (hasta 200 m en la veta San Cristóbal). Estas estructuras de tensión y cizalla sirvieron de conductos para la circulación de fluidos hidrotermales. Además, se reconocen zonas de brechamiento y stockwork asociadas a los intrusivos porfiríticos, particularmente cerca del lithocap Chumpe.

2.3.3.3 Geología local

A escala local, el área de la mina San Cristóbal está dominada por rocas del Grupo Mitú (volcánicas y piroclásticas andesíticas) y filitas del Grupo Excelsior, intruidas por el stock porfirítico San Cristóbal. La mineralización se presenta principalmente como vetas de relleno de fracturas (ej. veta San Cristóbal, extensa de más de 3 km) y cuerpos de reemplazamiento en calizas del Grupo Pucará (mantos). La paragénesis incluye tres etapas principales: cuarzo-pirita-wolframita (temprana), metales base (esfalerita, galena, calcopirita – la más económica) y carbonatos tardíos. Se observa una zonación vertical y lateral con enriquecimiento de Cu y W en profundidad, Zn-Pb en niveles intermedios y Ag en partes superiores. La alteración hidrotermal es predominantemente sericitica (illita, muscovita, cuarzo) con halo de carbonatos.

2.3.4 Tipo de yacimiento

La Unidad Minera San Cristóbal corresponde a un yacimiento polimetálico cordillerano de tipo hidrotermal, caracterizado principalmente por mineralización en vetas de relleno de fracturas y cuerpos de reemplazamiento (mantos). Se enmarca dentro del Domo de Yauli, en un ambiente epitermal de sulfidación intermedia a mesotermal, asociado a intrusivos porfiríticos de composición cuarzo-monzonítica. La mineralización económica principal está compuesta por zinc, plomo y plata, con contenidos accesorios de cobre y, localmente, tungsteno.

2.3.4.1 Mineralización

La mineralización en San Cristóbal se presenta de dos formas principales:

- Vetas de relleno de fracturas (principalmente la veta San Cristóbal y ramales como 658, SP 658, 722, Sheyla, entre otras), que siguen direcciones preferentes NW-SE y NE-SW.
- Cuerpos de reemplazamiento (mantos) en calizas del Grupo Pucará.

La paragénesis muestra zonación vertical y lateral típica de depósitos cordilleranos: wolframita y calcopirita en zonas profundas o proximales, esfalerita y galena en niveles intermedios (la más económica), y mayor contenido de plata en partes superiores. Se reconocen al menos tres etapas hidrotermales: una temprana cuarzo-pirita-wolframita, una principal de metales base (esfalerita-galena-calcopirita) y una tardía de carbonatos. La alteración asociada es predominantemente sericitica, silicificada y carbonatada.

2.3.5 Reservas

De acuerdo con la Memoria Anual 2024 de Volcan Compañía Minera, las reservas probadas y probables de la mina San Cristóbal - Carahuacra (integradas desde 2023) alcanzan 12.09 millones de toneladas con leyes promedio de 4.39% Zn, 0.67% Pb, 0.13% Cu y 2.73 oz/t Ag. De estas, las reservas probadas corresponden a 3.86 millones de toneladas (4.65% Zn, 0.63% Pb, 0.12% Cu y 2.87 oz/t Ag) y las probables a 8.23 millones de toneladas (4.26% Zn, 0.69% Pb, 0.14% Cu y 2.66 oz/t Ag). Estas reservas forman parte del clúster Yauli y se encuentran en proceso de ampliación mediante campañas de exploración destinadas a extender la vida útil de la unidad.

2.4 Método de explotación

La Unidad Minera San Cristóbal es una operación subterránea que emplea principalmente métodos de explotación selectivos adaptados a la geometría de las

vetas y cuerpos de reemplazamiento polimetálicos. Los métodos predominantes son el Sublevel Stopping (taladros largos o hundimiento por subniveles) y el Over Cut and Fill (corte y relleno ascendente, también conocido como breasting). Adicionalmente, se utiliza el método Bench and Fill (variante de Avoca) en sectores específicos para optimizar la productividad y reducir la dilución.

El Sublevel Stopping representa el método principal, especialmente en vetas de mayor espesor y mejor calidad geomecánica, permitiendo una alta productividad mediante perforación de taladros largos, voladura en masa y extracción por gravedad o cargadores. Por su parte, el Over Cut and Fill se aplica en zonas de vetas más estrechas, mayor inestabilidad o mayor valor metalúrgico, donde se realiza la extracción en cortes horizontales ascendentes con posterior relleno hidráulico o pastoso para soporte estructural y control de la dilución.

La selección del método depende de factores como el ancho de la veta, el buzamiento, la calidad de la roca (RMR), la estabilidad y las leyes económicas. Actualmente, la mina opera con una combinación de estos métodos como parte del proyecto de integración San Cristóbal – Carahuacra, orientado a maximizar la recuperación de reservas y extender la vida útil de la unidad.

CAPÍTULO III

III. MATERIALES Y MÉTODOS

3.1 Tipo de investigación

La investigación es de tipo aplicada, ya que busca generar conocimiento práctico orientado a estimar la vida útil de la columna de perforación, con el propósito de mejorar la toma de decisiones en la operación minera.

3.2 Nivel de investigación

El nivel de la investigación es explicativo, debido a que se analiza la relación existente entre los parámetros de perforación (variables independientes) y la vida útil de la columna de perforación (variable dependiente), determinando el grado de influencia de cada variable mediante un modelo estadístico.

3.3 Diseño de investigación

El diseño de la investigación es no experimental – correlacional de tipo transversal.

- No experimental, porque no se manipulan deliberadamente las variables, sino que se analizan tal como se presentan en la operación real.
- Correlacional, porque se busca establecer la relación entre variables independientes y dependientes.
- Transversal, ya que los datos se recolectan en un periodo determinado de tiempo.

3.4 Población y muestra

3.4.1 Población

La población está constituida por todos los registros de perforación realizados por los equipos Jumbo en la Unidad Minera San Cristóbal, incluyendo los datos de parámetros operativos, condiciones geomecánicas y vida útil de los componentes de la columna de perforación.

3.4.2 Muestra

La muestra está conformada por los registros de perforación seleccionados correspondientes a un periodo específico de operación, los cuales cumplen con criterios de calidad y consistencia en la información. Se empleará un muestreo no probabilístico por conveniencia, considerando únicamente los datos completos y confiables para el análisis.

3.5 Formulación de hipótesis

3.5.1 Hipótesis general

La vida útil de la columna de perforación se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026.

3.5.2 Hipótesis específicas

1. La vida útil del shank se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple.
2. La vida útil de la barra se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple.
3. La vida útil de la broca se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple.
4. La vida útil del coupling se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple.

3.6 Variables e indicadores

3.6.1 Variable independiente (X)

Parámetros de perforación

Dimensiones

Parámetros operativos

- Presión de percusión (bar)
- Presión de rotación (bar)
- Presión de avance (bar)
- Velocidad de rotación (rpm)
- Presión de agua/barrido (bar)

Parámetros geomecánicos

- RMR (Rock Mass Rating)

Parámetros geométricos

- Diámetro de broca (mm)
- Profundidad de perforación (m)
- Longitud de borra(m)

3.6.2 Variable dependiente (Y)

Vida útil de la columna de perforación (m)

Indicadores:

Vida útil (metros perforados)

3.7 Operacionalización de variables

Tabla 10

Operacionalización de variables

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Unidad de medida
Variable Independiente (X): Parámetros operativos y geomecánicos	Son las condiciones técnicas y geomecánicas bajo las cuales se desarrolla el proceso de perforación, las cuales influyen en el rendimiento y desgaste de la columna de perforación.	Corresponde a los valores registrados durante la operación de perforación en la Unidad Minera San Cristóbal y utilizados como variables predictoras en el modelo de Regresión Lineal Múltiple.	Parámetros operativos	Presión de percusión	bar
				Presión rotación	bar
				Presión avance	bar
				Presión de agua	bar
				Presión de aire	bar
Variable Dependiente (Y): Vida útil de la columna de perforación	Es el rendimiento operativo alcanzado por los componentes de la columna de perforación antes de que deban ser reemplazados debido al desgaste producido durante las operaciones de perforación.	Corresponde a la vida útil registrada para cada componente de la columna de perforación y utilizada como variable respuesta durante el entrenamiento y validación del modelo de Regresión Lineal Múltiple.	Parámetro geomecánico	Índice RMR del macizo rocoso	Puntos (0–100)
			Shank	Vida útil del shank	metros perforados (m)
			Coupling	Vida útil del coupling	metros perforados (m)
			Barra	Vida útil de la barra	metros perforados (m)
			Broca	Vida útil de la broca	metros perforados (m)

3.8 Técnica e instrumentos de recolección de datos

3.8.1 Técnica de recolección de datos

La técnica empleada para la recolección de datos fue el análisis documental, debido a que la investigación se desarrolló a partir de información registrada durante las operaciones de perforación en la Unidad Minera San Cristóbal. Esta técnica permitió recopilar y analizar registros históricos correspondientes a los parámetros operativos de perforación y a la vida útil de los componentes de la columna de perforación, información necesaria para el desarrollo del modelo predictivo.

Los registros recopilados incluyeron las variables independientes: presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y clasificación geomecánica del macizo rocoso (RMR), así como las variables dependientes correspondientes a la vida útil del shank, coupling, barra y broca. Posteriormente, la información fue organizada y verificada para garantizar su consistencia antes de ser utilizada en el entrenamiento y validación de los modelos de Regresión Lineal Múltiple.

3.8.2 Instrumentos de la recolección de datos

Para la recolección de información se emplearon como instrumentos los registros operativos y geomecánicos generados durante las actividades de perforación en la Unidad Minera San Cristóbal. Dichos registros contienen información referente a las condiciones de operación del jumbo de perforación y al comportamiento de los componentes de la columna de perforación durante su vida útil.

Asimismo, se utilizaron hojas de cálculo en Microsoft Excel para la organización, codificación y depuración de la base de datos. Posteriormente, la información fue procesada mediante el lenguaje de programación Python, empleando bibliotecas especializadas para el análisis estadístico.

3.8.3 Procesamiento de datos

El procesamiento de los datos se realizó siguiendo un procedimiento sistemático orientado al desarrollo y validación de los modelos predictivos. Inicialmente, la información recopilada fue organizada en una base de datos estructurada, verificando la consistencia de los registros y eliminando datos incompletos o inconsistentes que pudieran afectar el desempeño del modelo.

Posteriormente, se seleccionaron las variables independientes (presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR) y las variables dependientes correspondientes a la vida útil del shank, coupling, barra y broca. Los datos fueron divididos en conjuntos de entrenamiento y prueba, aplicándose un proceso de estandarización a las variables predictoras con la finalidad de mejorar el comportamiento estadístico del modelo.

El entrenamiento de los modelos se realizó mediante la técnica de Regresión Lineal Múltiple utilizando el lenguaje de programación Python. Para ello se emplearon bibliotecas especializadas como Pandas para la manipulación de datos, NumPy para el procesamiento numérico, Scikit-learn para el entrenamiento, evaluación y validación del modelo predictivo, y Statsmodels para el análisis estadístico de los coeficientes y la verificación de los supuestos de la regresión.

Finalmente, los modelos fue evaluado mediante indicadores estadísticos como el coeficiente de determinación (R^2), coeficiente de determinación ajustado (R^2 ajustado), error absoluto medio (MAE), y raíz del error cuadrático medio (RMSE). Asimismo, se verificó el cumplimiento de los supuestos de la Regresión Lineal Múltiple, incluyendo la normalidad de los residuos, la homocedasticidad y la ausencia de multicolinealidad, garantizando la confiabilidad de las ecuaciones obtenidas para la predicción de la vida útil de los componentes de la columna de perforación.

CAPÍTULO IV

IV. RESULTADO Y DISCUSIÓN

En el presente capítulo se desarrolla el modelo de regresión lineal múltiple para predecir la vida útil de los componentes que conforman la columna de perforación: shank, coupling, barra y broca, a partir de parámetros operativos, geomecánicos y geométricos registrados durante las operaciones de perforación en la Unidad Minera San Cristóbal. Las variables independientes y dependientes empleadas en la construcción de los modelos se presentan en la Tabla 11.

Para el desarrollo de los modelos predictivos se empleó el lenguaje de programación Python, utilizando las bibliotecas Pandas para la manipulación y procesamiento de los datos; NumPy para operaciones numéricas; Scikit-learn (sklearn) para el preprocesamiento de las variables mediante StandardScaler, la división del conjunto de datos en entrenamiento y prueba (train_test_split), el entrenamiento del modelo de regresión lineal múltiple (LinearRegression) y la evaluación de su desempeño mediante las métricas R^2 (coeficiente de determinación), MAE (error absoluto medio) y RMSE (raíz del error cuadrático medio); Statsmodels para la validación estadística del modelo y el análisis de la significancia de los coeficientes de regresión; Matplotlib para la generación de gráficos de evaluación del modelo; y Joblib para el almacenamiento y posterior reutilización de los modelos entrenados y del objeto de escalamiento.

El capítulo se estructura en varias etapas. En primer lugar, se describe el conjunto de datos utilizado para el entrenamiento de los modelos, indicando el número de registros, el período de recolección de la información, las variables consideradas y los equipos involucrados en la obtención de los datos. Posteriormente, se presenta el

proceso de construcción y entrenamiento de los modelos de regresión lineal múltiple mediante Python.

Debido a que la columna de perforación está conformada por cuatro componentes principales, se desarrollan cuatro modelos predictivos independientes, uno para cada elemento (shank, barra, broca y coupling). Para cada modelo se presenta la ecuación de regresión obtenida, la evaluación de su desempeño mediante indicadores estadísticos, el análisis gráfico de los resultados y la validación estadística correspondiente. Finalmente, se discuten los resultados obtenidos y su aplicación para la estimación de la vida útil de los componentes de la columna de perforación.

Tabla 11

Variables independientes y dependientes para el entrenamiento del modelo

Variable	Tipo	Unidad
Presión de percusión	Independiente	bar
Presión de rotación	Independiente	bar
Presión de avance	Independiente	bar
Presión de agua	Independiente	bar
Presión de aire	Independiente	bar
RMR	Independiente	-
Diámetro de broca	Independiente	mm
Vida útil del shank	Dependiente	m perforados
Vida útil de la barra	Dependiente	m perforados
Vida útil de la broca	Dependiente	m perforados
Vida útil del coupling	Dependiente	m perforados

Nota. Elaboración propia.

4.1 Descripción del conjunto de datos

El conjunto de datos utilizado para el desarrollo de los modelos de regresión lineal múltiple fue obtenido a partir de los registros operacionales de perforación de la Unidad Minera San Cristóbal, correspondientes a las labores de desarrollo ejecutadas con equipos Epiroc BOOMER S1D durante el periodo comprendido entre enero 2024 y abril de 2025. La información fue recopilada a partir de los reportes diarios de

perforación, registros operacionales de los equipos y bases de datos generadas por el área de Operaciones Mina.

La base de datos, donde cada registro representa un evento de perforación asociado al desempeño de la columna de perforación y a las condiciones operativas bajo las cuales se desarrolló la actividad. Para cada registro se recopilaron los parámetros operativos, geomecánicos y geométricos considerados como variables independientes, así como la vida útil alcanzada por cada componente de la columna de perforación, utilizada como variable dependiente en los diferentes modelos.

Los equipos considerados en la investigación corresponden a jumbos electrohidráulicos de desarrollo utilizados en las labores subterráneas de la Unidad Minera San Cristóbal, equipados con columnas de perforación compuestas por shank, coupling, barra y broca.

Previo a la construcción de los modelos predictivos, la base de datos fue sometida a un proceso de depuración y preparación utilizando el lenguaje de programación Python y la biblioteca Pandas. En esta etapa se verificó la consistencia de la información, se seleccionaron únicamente las variables de interés y se eliminaron aquellos registros que presentaban valores faltantes o información incompleta mediante el método `dropna()`, garantizando que todas las observaciones utilizadas durante el entrenamiento del modelo contaran con información completa.

La Tabla 11 presenta las variables utilizadas para la construcción de los modelos predictivos, indicando el tipo de variable, la unidad de medida y su clasificación dentro del modelo de regresión lineal múltiple.

4.2 Explicación del código

En esta sección se describe el procedimiento seguido para la construcción del modelo de regresión lineal múltiple mediante Python. El proceso fue implementado

mediante tres scripts independientes, cada uno con una función específica dentro del flujo de trabajo del modelo predictivo.

- **Entrenamiento.py:** encargado de construir y entrenar el modelo de regresión lineal múltiple.
- **Analisis_Statsmodels.py:** utilizado para realizar la validación estadística del modelo mediante pruebas de significancia e indicadores estadísticos.
- **Predecir.py:** empleado para estimar la vida útil de nuevos componentes utilizando el modelo previamente entrenado.

Debido a que el procedimiento es el mismo para los cuatro componentes de la columna de perforación (shank, barra, broca y coupling), únicamente se describe el código desarrollado para el modelo correspondiente al shank. Los demás modelos siguen exactamente la misma metodología, modificándose únicamente la variable dependiente correspondiente a cada componente.

El código fuente completo desarrollado en Python se presenta del Anexo 2 al Anexo 5.

4.2.1 Entrenamiento.py

4.2.1.1 Importación de bibliotecas

```
=====
# ENTRENAMIENTO DEL MODELO
# =====

import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
from joblib import dump
from sklearn.metrics import r2_score, mean_absolute_error,
root_mean_squared_error
```

Este bloque importa las bibliotecas y funciones necesarias para el procesamiento de datos, entrenamiento, evaluación y almacenamiento del modelo. La biblioteca pandas se emplea para la lectura y manipulación de la base de datos. La biblioteca matplotlib.pyplot permite generar la representación gráfica de los valores reales y predichos.

Asimismo, se importa StandardScaler, utilizado para estandarizar las variables independientes; train_test_split, para dividir la base de datos en conjuntos de entrenamiento y prueba; y LinearRegression, correspondiente al algoritmo de regresión lineal múltiple empleado en la investigación.

Finalmente, se importan las métricas R^2 , MAE y RMSE para evaluar el desempeño predictivo del modelo, mientras que la función dump de la biblioteca joblib permite guardar el modelo entrenado y el normalizador para su posterior utilización.

4.2.1.2 Carga de la base de datos

```
# =====  
# Cargar datos  
# =====  
  
csv_data = "Datos/Datos_shank.xlsx"  
df = pd.read_excel(csv_data)
```

En este bloque se define la ruta del archivo que contiene la base de datos experimental y se realiza su lectura mediante la función read_excel() de la biblioteca pandas. La información contenida en el archivo Excel se almacena en un objeto denominado df, que corresponde a un DataFrame.

Este procedimiento permite transformar la información tabular de la base de datos en una estructura que puede ser procesada estadísticamente por el algoritmo.

4.2.1.3 Selección de las variables de estudio

```
# Seleccionar columnas

df = df[["Vida_Shank", "Presion_Percusion", "Presion_Rotacion",
"Presion_Avance", "Presion_Agua", "Presion_Aire", "RMR"]]
```

En este bloque se seleccionan únicamente las variables empleadas en el desarrollo del modelo predictivo. La variable Vida_Shank corresponde a la variable dependiente, mientras que las variables Presion_Percusion, Presion_Rotacion, Presion_Avance, Presion_Agua, Presion_Aire y RMR corresponden a las variables independientes.

La selección explícita de las columnas permite excluir variables que no forman parte del modelo y garantiza que el algoritmo trabaje únicamente con los parámetros definidos en la investigación.

4.2.1.4 Eliminación de datos faltantes

```
# Eliminar datos faltantes

df = df.dropna()
```

La función dropna() elimina los registros que contienen valores faltantes en cualquiera de las variables seleccionadas. Esta etapa es necesaria porque los algoritmos de regresión requieren datos completos para realizar correctamente el ajuste matemático del modelo.

De esta manera, el entrenamiento se realiza utilizando únicamente observaciones que cuentan con información disponible tanto para la variable dependiente como para las variables independientes.

4.2.1.5 Definición de la variable dependiente e independientes

```
# =====
# Variables independientes y dependiente
```

```
# =====
y = df[["Vida_Shank"]]
X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",
"Presion_Agua", "Presion_Aire", "RMR"]]
```

En este bloque se separan las variables utilizadas en el proceso de modelamiento. La variable *y* representa la variable dependiente, correspondiente a la vida útil del shank.

Por otro lado, la matriz *X* contiene las variables independientes que se utilizarán para explicar y predecir la vida útil del componente:

$$X = \{\text{Presión de percusión, Presión de Rotación, Presión de avance,} \\ \text{Presión de agua, Presión de aire, RMR}\}$$

Por tanto, el modelo busca estimar la variable dependiente y a partir de las seis variables independientes incluidas en la matriz *X*.

4.2.1.6 División de los datos en entrenamiento y prueba

```
X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.20,
    random_state=42
)
```

Este bloque divide la base de datos en dos subconjuntos. El 80 % de los datos se utiliza para entrenar el modelo y el 20 % restante se reserva para evaluar su desempeño predictivo.

El conjunto de entrenamiento está constituido por *X_train* y *Y_train*, mientras que el conjunto de prueba está conformado por *X_test* y *Y_test*.

La división de los datos permite evaluar el modelo utilizando observaciones que no fueron empleadas directamente durante su entrenamiento. De esta forma, se obtiene una estimación de su capacidad para realizar predicciones sobre nuevos datos.

El parámetro `random_state=42` permite que la división de los datos sea reproducible. Es decir, cada vez que se ejecuta el código con la misma base de datos se obtiene la misma distribución entre los conjuntos de entrenamiento y prueba.

4.2.1.7 Estandarización de las variables independientes

```
# =====  
# Escalamiento de variables  
# =====  
  
scaler = StandardScaler()  
  
X_train = scaler.fit_transform(X_train)
```

En este bloque se crea un objeto `StandardScaler` para estandarizar las variables independientes del conjunto de entrenamiento.

La estandarización transforma cada variable mediante la siguiente expresión:

$$Z = \frac{X - \mu}{\sigma}$$

donde:

- X es el valor original;
- μ es la media de la variable;
- σ es la desviación estándar;
- Z es el valor estandarizado.

Este procedimiento permite que las variables sean expresadas en una escala comparable, evitando que las diferencias en sus unidades y magnitudes influyan en la estimación de los coeficientes del modelo.

4.2.1.8 Transformación del conjunto de prueba

```
X_test = scaler.transform(X_test)
```

El conjunto de prueba se transforma utilizando los parámetros calculados previamente a partir del conjunto de entrenamiento.

Este aspecto es importante porque el modelo no debe utilizar información estadística del conjunto de prueba durante el entrenamiento. Por ello, no se vuelve a calcular la media ni la desviación estándar del conjunto de prueba.

El procedimiento garantiza que los datos de entrenamiento y prueba sean transformados bajo los mismos parámetros, evitando la introducción de información externa al proceso de aprendizaje del modelo.

4.2.1.9 Creación y entrenamiento del modelo

```
=====
# Entrenar modelo
# =====

modelo = LinearRegression()
modelo.fit(X_train, y_train)
```

En este bloque se crea el modelo de regresión lineal múltiple mediante la clase `LinearRegression`.

Posteriormente, mediante el método `fit()`, el modelo es entrenado utilizando las variables independientes estandarizadas (`X_train`) y los valores observados de vida útil del shank (`y_train`).

Durante esta etapa, el algoritmo estima el intercepto y los coeficientes de regresión que permiten establecer la relación matemática entre las variables independientes y la vida útil del shank.

La forma general del modelo es:

$$\hat{Y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5 + \beta_6 X_6$$

donde $\hat{Y}$ representa la vida útil estimada del shank.

4.2.1.10 Obtención del intercepto y los coeficientes

```
# =====  
# Resultados  
# =====  
  
print("\nIntercepto:")  
  
print(modelo.intercept_)  
  
print("\nCoeficientes:")  
  
print(modelo.coef_)
```

Este bloque permite visualizar los parámetros estimados por el modelo. El `intercept_` corresponde al intercepto β_0 , mientras que `coef_` contiene los coeficientes asociados a cada una de las variables independientes.

Los coeficientes permiten identificar la dirección de la relación entre cada variable predictora y la vida útil estimada. El signo positivo indica una relación directa, mientras que el signo negativo representa una relación inversa, manteniendo constantes las demás variables del modelo.

Debido a que las variables fueron estandarizadas antes del entrenamiento, estos coeficientes corresponden a coeficientes calculados sobre variables estandarizadas.

4.2.1.11 Generación de predicciones

```
# Predicciones sobre el conjunto de prueba
```

```
y_pred = modelo.predict(X_test)
```

En este bloque se generan las predicciones de vida útil del shank utilizando las variables independientes correspondientes al conjunto de prueba.

El resultado se almacena en la variable `y_pred`, que contiene los valores estimados por el modelo. Estos valores posteriormente se comparan con los valores reales contenidos en `y_test`.

4.2.1.12 Evaluación del desempeño predictivo

```
# Calcular métricas
r2 = r2_score(y_test, y_pred)

mae = mean_absolute_error(y_test, y_pred)

rmse = root_mean_squared_error(y_test, y_pred)
```

En este bloque se calculan las métricas utilizadas para evaluar el desempeño del modelo.

El coeficiente de determinación R^2 permite determinar la proporción de la variabilidad de la vida útil del shank explicada por las variables independientes. El error absoluto medio (MAE) representa el error promedio de las predicciones en las unidades originales de la variable dependiente. Por su parte, la raíz del error cuadrático medio (RMSE) mide la magnitud promedio del error de predicción, otorgando mayor peso a los errores de mayor magnitud. La utilización conjunta de estas métricas permite realizar una evaluación más completa del desempeño del modelo.

4.2.1.13 Representación gráfica de los valores reales y predichos

```
# =====
# GRÁFICO: VALORES REALES VS. VALORES PREDICHOS
# =====
```

```
plt.figure(figsize=(9, 7))
```

Este bloque genera un gráfico de dispersión que relaciona los valores reales de vida útil del shank con los valores predichos por el modelo.

Asimismo, se incorpora la línea de referencia:

$$y=x$$

Esta línea representa una predicción perfecta. Por lo tanto, cuanto más próximos se encuentren los puntos a dicha línea, menor será la diferencia entre los valores observados y los valores estimados.

El gráfico también incorpora las métricas R2, MAE y RMSE, facilitando la interpretación visual y numérica del desempeño predictivo.

4.2.1.14 Almacenamiento del modelo entrenado

```
# =====  
# Guardar modelo y normalizador  
# =====  
  
dump(modelo, "linear_regression.joblib")  
  
dump(scaler, "scaler.joblib")  
  
print("\nModelo guardado correctamente.")  
print("StandardScaler guardado correctamente.")
```

Finalmente, el modelo de regresión lineal entrenado y el objeto de estandarización son almacenados en archivos independientes mediante la función `dump()`.

El archivo `linear_regression.joblib` contiene los parámetros aprendidos por el modelo, mientras que `scaler.joblib` conserva los parámetros de estandarización calculados durante el entrenamiento.

La conservación de ambos archivos permite utilizar posteriormente el modelo para realizar predicciones sobre nuevos datos, aplicando previamente el mismo procedimiento de transformación utilizado durante la fase de entrenamiento.

4.2.2 Analisis_Statsmodels.py

Con la finalidad de complementar el análisis predictivo del modelo, se desarrolló un segundo procedimiento computacional mediante la biblioteca statsmodels. Este procedimiento permitió obtener información estadística detallada sobre los coeficientes de regresión, sus errores estándar, los estadísticos t, los valores de significancia p, el coeficiente de determinación R^2 y el R^2 ajustado.

4.2.2.1 Importación de las bibliotecas

```
# =====  
# REGRESIÓN LINEAL MÚLTIPLE CON STATSMODELS  
# =====  
  
import pandas as pd  
import numpy as np  
import statsmodels.api as sm  
  
from sklearn.model_selection import train_test_split  
from sklearn.preprocessing import StandardScaler
```

Este bloque importa las bibliotecas necesarias para el procesamiento de los datos y el análisis estadístico.

La biblioteca pandas se utiliza para leer y manipular la base de datos. La biblioteca numpy proporciona herramientas para el procesamiento numérico. Por su parte, statsmodels constituye la biblioteca principal utilizada para estimar el modelo de regresión mediante el método de Mínimos Cuadrados Ordinarios (Ordinary Least Squares, OLS)

Asimismo, se importan las funciones `train_test_split` y `StandardScaler` de la biblioteca `scikit-learn`. La primera permite dividir la base de datos en conjuntos de entrenamiento y prueba, mientras que la segunda permite estandarizar las variables independientes.

4.2.2.2 Carga de la base de datos

```
# =====  
# Cargar datos  
# =====  
  
csv_data = "Datos/Datos_shank.xlsx"  
  
df = pd.read_excel(  
    csv_data  
)
```

En este bloque se establece la ubicación del archivo Excel que contiene los datos utilizados en la investigación.

La función `pd.read_excel()` permite leer la información almacenada en el archivo y convertirla en un `DataFrame` denominado `df`. Esta estructura permite organizar y procesar las observaciones correspondientes a la vida útil del shank y a las variables operativas y geomecánicas consideradas en el estudio.

4.2.2.3 Selección de las variables utilizadas en el análisis

```
# =====  
# Seleccionar variables  
# =====  
  
df = df[["Vida_Shank", "Presion_Percusion", "Presion_Rotacion",  
        "Presion_Avance", "Presion_Agua", "Presion_Aire", "RMR"]]
```

Este bloque selecciona exclusivamente las variables que forman parte del análisis estadístico.

La variable Vida_Shank corresponde a la variable dependiente, mientras que las variables:

- Presion_Percusion
- Presion_Rotacion
- Presion_Avance
- Presion_Agua
- Presion_Aire
- RMR

constituyen las variables independientes del modelo.

La selección explícita permite asegurar que el análisis se realice únicamente con las variables definidas previamente en la investigación.

4.2.2.4 Eliminación de datos faltantes

```
# Eliminar datos faltantes  
  
df = df.dropna()
```

La función dropna() elimina las observaciones que contienen valores faltantes en alguna de las variables seleccionadas.

Esta etapa permite trabajar con una base de datos completa para el ajuste del modelo de regresión. La eliminación de observaciones incompletas evita que los valores ausentes interfieran con el cálculo de los parámetros estadísticos del modelo.

4.2.2.5 Definición de la variable dependiente e independientes

```
# =====  
# Variables dependiente e independientes  
# =====  
  
y = df["Vida_Shank"]
```

```
X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",
"Presion_Agua", "Presion_Aire", "RMR"]]
```

En este bloque se separan las variables utilizadas en el análisis de regresión.

La variable y representa la variable dependiente:

y=Vida útil del shank

La matriz X contiene las seis variables independientes utilizadas para explicar la variabilidad de la vida útil:

$$X = [X_1 \ X_2 \ X_3 \ X_4 \ X_5 \ X_6]$$

donde:

X_1 = Presión de percusión

X_2 = Presión de rotación

X_3 = Presión de avance

X_4 = Presión de agua

X_5 = Presión de aire

X_6 = RMR

Por consiguiente, el modelo busca determinar la relación estadística existente entre estas variables y la vida útil del shank.

4.2.2.6 División de la base de datos

```
# =====
# División entrenamiento / prueba
# =====

X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.20,
    random_state=42
)
```

Este bloque divide la base de datos en dos subconjuntos.

El 80 % de las observaciones se destina al conjunto de entrenamiento, mientras que el 20 % restante se reserva para el conjunto de prueba.

El conjunto de entrenamiento se utiliza para estimar los parámetros del modelo:

$$X_{\text{train}}, y_{\text{train}}$$

Por otro lado, el conjunto de prueba:

$$X_{\text{test}}, y_{\text{test}}$$

se mantiene separado del proceso de ajuste.

El parámetro `random_state=42` permite reproducir exactamente la misma división de los datos en ejecuciones posteriores.

4.2.2.7 Estandarización de las variables independientes

```
# =====  
# Escalamiento  
# =====  
  
scaler = StandardScaler()  
  
X_train = scaler.fit_transform(X_train)  
  
X_test = scaler.transform(X_test)
```

En este bloque se estandarizan las variables independientes.

La transformación se realiza mediante:

$$Z = \frac{X - \mu}{\sigma}$$

donde:

- X representa el valor original
- μ es la media calculada

- σ es la desviación estándar
- Z es el valor estandarizado

El método `fit_transform()` calcula los parámetros estadísticos utilizando únicamente el conjunto de entrenamiento y posteriormente transforma dichos datos. Luego, mediante `transform()`, el conjunto de prueba se transforma utilizando los mismos parámetros obtenidos del conjunto de entrenamiento. Esta secuencia evita que la información estadística del conjunto de prueba sea utilizada durante el ajuste del modelo.

4.2.2.8 Incorporación del término independiente

```
# =====
# Agregar el intercepto
# =====
X_train = sm.add_constant(X_train)
```

Este bloque incorpora una columna de unos a la matriz de variables independientes.

La finalidad es incluir el término independiente o intercepto β_0 en la ecuación de regresión.

La forma general del modelo es:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5 + \beta_6 X_6 + \varepsilon$$

El término:

$$\beta_0$$

representa el valor esperado de la variable dependiente cuando todas las variables independientes toman el valor cero.

La función `sm.add_constant()` agrega automáticamente esta columna de unos, permitiendo que `statsmodels` estime el intercepto del modelo.

4.2.2.9 Creación del modelo OLS

```
# =====  
# Entrenar modelo OLS  
# =====  
  
modelo = sm.OLS(y_train, X_train)
```

En este bloque se define un modelo de regresión lineal mediante el método de Mínimos Cuadrados Ordinarios.

La función `sm.OLS()` recibe:

- `y_train`: variable dependiente;
- `X_train`: variables independientes estandarizadas, incluyendo el intercepto.

El objetivo del método OLS es estimar los coeficientes que minimizan la suma de los cuadrados de los residuos:

$$\min_{\beta} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

donde:

- y_i es el valor observado
- $\hat{y}_i$ es el valor estimado
- $y_i - \hat{y}_i$ representa el residuo

De esta manera, el modelo identifica los coeficientes que producen el mejor ajuste lineal posible para los datos de entrenamiento.

4.2.2.10 Ajuste del modelo estadístico

```
resultado = modelo.fit()
```

El método `fit()` realiza el ajuste estadístico del modelo.

Durante esta etapa se estiman:

- el intercepto
- los coeficientes de regresión
- los errores estándar
- los estadísticos t
- los valores p
- R^2
- R^2 ajustado
- y otras estadísticas de diagnóstico

El objeto resultado almacena todos los resultados estadísticos obtenidos durante el ajuste del modelo.

4.2.2.11 Obtención del resumen estadístico completo

```
# =====  
# Resumen completo  
# =====  
  
print("\n")  
print("="*80)  
print("RESUMEN DEL MODELO")  
print("="*80)  
  
print(resultado.summary())
```

Este bloque imprime el resumen estadístico completo del modelo.

El resultado generado por statsmodels contiene información relevante para evaluar tanto el ajuste global como la significancia estadística de las variables independientes.

Entre los principales resultados se encuentran:

- Número de observaciones
- Grados de libertad

- R^2
- R^2 ajustado
- Estadístico f
- Probabilidad asociada al estadístico f
- Coeficientes estimados
- Errores estándar
- Estadísticos t
- Valores p
- Intervalos de confianza

Por tanto, este resumen permite realizar una evaluación estadística más completa que la obtenida únicamente mediante las métricas de predicción.

4.2.2.12 Extracción de los parámetros estadísticos

```
# Parámetros del modelo
# =====

print("\n")
print("="*80)
print("COEFICIENTES")
print("="*80)

coeficientes = pd.DataFrame({

    "Coeficiente": resultado.params,
    "Error estándar": resultado.bse,
    "t": resultado.tvalues,
    "p-value": resultado.pvalues

})

print(coeficientes)
```

Este bloque organiza los principales parámetros estadísticos del modelo en una tabla.

4.2.2.13 Cálculo del coeficiente de determinación

```
print(f"R² : {resultado.rsquared:.4f}")
```

El coeficiente de determinación R^2 permite cuantificar la proporción de la variabilidad de la vida útil del shank que es explicada por el conjunto de variables independientes incluidas en el modelo.

Su expresión general es:

$$[R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}]$$

Un valor de R^2 más próximo a 1 indica que el modelo explica una mayor proporción de la variabilidad observada en la variable dependiente.

Sin embargo, el R^2 no debe interpretarse de manera aislada, ya que su valor puede aumentar al incorporar nuevas variables al modelo, incluso cuando estas no aportan una mejora sustancial.

4.2.2.14 Cálculo del R^2 ajustado

```
print(f"R² Ajustado : {resultado.rsquared_adj:.4f}")
```

El R^2 ajustado corrige el coeficiente de determinación considerando el número de variables independientes y el tamaño de la muestra. Su utilidad principal consiste en proporcionar una medida más rigurosa del ajuste del modelo cuando se trabaja con múltiples variables predictoras. A diferencia del R^2 convencional, el R^2 ajustado puede disminuir cuando se incorpora una variable que no mejora suficientemente la capacidad explicativa del modelo. Por ello, resulta especialmente útil para comparar modelos de regresión que poseen diferente número de variables independientes.

El análisis estadístico mediante el método de Mínimos Cuadrados Ordinarios permitió complementar la evaluación predictiva del modelo de regresión lineal múltiple. Mientras que el modelo predictivo permitió estimar la vida útil del shank a partir de las variables operativas y geomecánicas, el análisis desarrollado mediante statsmodels permitió evaluar la significancia estadística individual de los coeficientes mediante los estadísticos t y los valores p. Asimismo, se obtuvieron los valores de R^2 y R^2 ajustado para evaluar la capacidad explicativa global del modelo.

4.2.3 Predecir.py

Una vez entrenado y evaluado el modelo, se desarrolló un código para realizar predicciones utilizando nuevos datos de operación.

4.2.3.1 Carga del modelo y del escalador

```
# =====  
# PREDICCIÓN CON DATOS NUEVOS  
# =====  
  
from joblib import load  
  
# =====  
# Cargar modelo y StandardScaler  
# =====  
  
modelo = load("linear_regression.joblib")  
  
scaler = load("scaler.joblib")
```

Este bloque carga el modelo de regresión lineal y el objeto StandardScaler previamente guardados durante la etapa de entrenamiento. De esta manera, se reutilizan los parámetros aprendidos sin necesidad de entrenar nuevamente el modelo.

4.2.3.2 Ingreso de nuevos datos

```
# =====  
# Nuevo dato  
# =====
```

```

presion_percusion = 190.0

presion_rotacion = 45.0

presion_avance = 75.0

presion_agua = 8.0

presion_aire = 6.5

rmr = 55.0

```

En este bloque se ingresan los valores correspondientes a un nuevo escenario de operación y calidad del macizo rocoso. Estos datos representan las variables independientes utilizadas por el modelo para estimar la vida útil del shank.

4.2.3.3 Estandarización de los nuevos datos

```

# =====
nuevo_escalado = scaler.transform(nuevo)

```

Los nuevos valores son transformados utilizando los mismos parámetros de estandarización obtenidos durante el entrenamiento. Esto garantiza que los datos de entrada mantengan la misma escala utilizada por el modelo.

4.2.3.4 Generación de la predicción

```

# =====
# Predicción
# =====

vida_shank = modelo.predict(nuevo_escalado)

```

Finalmente, los datos estandarizados son ingresados al modelo previamente entrenado, el cual genera la estimación de la vida útil del shank para las condiciones operativas y geomecánicas proporcionadas.

El resultado se muestra junto con los valores de entrada, permitiendo conocer la vida útil estimada para el escenario analizado.

4.3 Desarrollo del Modelo 1: Shank

4.3.1 Entrenamiento y evaluación del modelo de regresión lineal múltiple para el shank(Entrenamiento.py)

Una vez preparado el conjunto de datos y realizado el escalamiento de las variables independientes mediante el algoritmo StandardScaler, se procedió al entrenamiento del modelo de regresión lineal múltiple utilizando la clase LinearRegression de la biblioteca Scikit-learn. En el modelo actualizado se consideraron seis variables independientes: presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. Durante este proceso, el algoritmo estimó el intercepto y los coeficientes asociados a cada variable mediante el método de mínimos cuadrados ordinarios.

Como resultado del entrenamiento, se obtuvo un intercepto igual a 3628.3. Los coeficientes estimados para las variables independientes se presentan en la **Tabla 12**.

Tabla 12

Coefficientes del modelo de regresión lineal múltiple para la predicción de la vida útil del shank

Variable	Coefficiente
Intercepto	3628.3233
Presión de percusión	-1060.9405
Presión de rotación	-763.9274
Presión de avance	-810.1520
Presión de agua	446.7786
Presión de aire	351.6689
RMR	-860.6001

Nota. Elaboración propia.

A partir de los coeficientes estimados, la ecuación del modelo de regresión lineal múltiple queda expresada de la siguiente manera:

$$\begin{aligned} \text{Vida}_{\text{Shank}} = & 3628.3233 - 1060.9405(\text{Presión de percusión}) \\ & - 763.9274(\text{Presión de rotación}) - 810.1520(\text{Presión de avance}) \\ & + 446.7786(\text{Presión de agua}) + 351.6689(\text{Presión de aire}) \\ & - 860.6001(\text{RMR}) \end{aligned}$$

La ecuación representa el modelo matemático obtenido durante el entrenamiento y permite estimar la vida útil del shank a partir de los parámetros operativos y geomecánicos considerados. El signo positivo de un coeficiente representa una relación directa con la vida útil estimada, mientras que el signo negativo representa una relación inversa, manteniendo constantes las demás variables. No obstante, la interpretación individual de cada coeficiente debe realizarse con cautela debido a que las variables independientes fueron previamente estandarizadas mediante StandardScaler, por lo que los coeficientes corresponden a variables expresadas en unidades estandarizadas y no en sus unidades originales de medición.

Posteriormente, el desempeño predictivo del modelo fue evaluado utilizando el conjunto de datos de prueba, obteniéndose los indicadores mostrados en la Tabla 13.

Tabla 13

Métricas de evaluación del modelo de regresión lineal múltiple

Métrica	Valor
Coefficiente de determinación (R ²)	0.9236
Error absoluto medio (MAE)	415.9844
Raíz del error cuadrático medio (RMSE)	452.2358

Nota. Elaboración propia.

El coeficiente de determinación obtenido fue de R²=0.9236, lo que indica que el modelo explica aproximadamente el 92.36 % de la variabilidad observada en la vida


útil del shank. Este resultado evidencia una elevada capacidad explicativa conjunta de la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR.

Por su parte, el Error Absoluto Medio fue de 415.9844, lo que significa que las predicciones del modelo difieren, en promedio, aproximadamente 415.98 unidades de vida útil respecto de los valores reales observados. Asimismo, la Raíz del Error Cuadrático Medio alcanzó un valor de 452.2358. Debido a que esta métrica penaliza con mayor intensidad los errores de mayor magnitud, su resultado permite evaluar la dispersión general de las predicciones respecto de los valores reales.

Finalmente, la Figura 22 presenta la comparación entre los valores reales y los valores predichos por el modelo actualizado de regresión lineal múltiple.

Figura 22

Comparación entre la vida útil real y la vida útil predicha para el modelo del shank



Nota. Elaboración propia.

En la Figura 22 se observa que la mayor parte de las observaciones se concentra alrededor de la línea de predicción perfecta ($y=x$), lo que evidencia una adecuada capacidad del modelo para reproducir el comportamiento de los datos evaluados. Aunque pueden presentarse algunas desviaciones puntuales, la distribución general de los valores confirma una concordancia elevada entre los resultados reales y los estimados. Esta apreciación gráfica es consistente con el coeficiente de determinación obtenido, mediante el cual el modelo actualizado explica el 92.36 % de la variabilidad de la vida útil del shank.

4.3.2 Validación estadística del modelo (Análisis_Statsmodels.py)

Con el propósito de verificar la validez estadística del modelo de regresión lineal múltiple desarrollado para estimar la vida útil del shank, se empleó la biblioteca Statsmodels de Python. A diferencia de Scikit-learn, cuya finalidad principal es el entrenamiento y la predicción, Statsmodels proporciona información estadística detallada que permite evaluar la significancia individual y conjunta de las variables independientes, la calidad del ajuste y algunos supuestos del modelo de regresión.

La Figura 23 presenta el resumen estadístico obtenido mediante la función `summary()`.

Figura 23

Resumen estadístico del modelo de regresión lineal múltiple para la vida útil del shank

OLS Regression Results						
=====						
Dep. Variable:	Vida_Shank	R-squared:	0.979			
Model:	OLS	Adj. R-squared:	0.976			
Method:	Least Squares	F-statistic:	388.5			
Date:	Tue, 25 Aug 2026	Prob (F-statistic):	9.41e-41			
Time:	10:49:27	Log-Likelihood:	-424.40			
No. Observations:	58	AIC:	862.8			
Df Residuals:	51	BIC:	877.2			
Df Model:	6					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]

const	3628.3233	51.028	71.104	0.000	3525.880	3730.766
x1	-1060.9405	57.144	-18.566	0.000	-1175.661	-946.220
x2	-763.9274	59.364	-12.868	0.000	-883.106	-644.748
x3	-810.1520	58.332	-13.889	0.000	-927.258	-693.046
x4	446.7786	52.470	8.515	0.000	341.441	552.117
x5	351.6689	53.881	6.527	0.000	243.497	459.841
x6	-860.6001	58.438	-14.727	0.000	-977.919	-743.281
=====						
Omnibus:	0.891	Durbin-Watson:	2.252			
Prob(Omnibus):	0.641	Jarque-Bera (JB):	0.941			
Skew:	-0.178	Prob(JB):	0.625			
Kurtosis:	2.487	Cond. No.	2.03			
=====						

Nota. Elaboración propia.

El modelo obtuvo un coeficiente de determinación R^2 de 0.9786, lo que indica que el 97.86 % de la variabilidad observada en la vida útil del shank es explicada conjuntamente por la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. Este resultado evidencia un elevado nivel de ajuste entre los valores observados y los estimados por el modelo.

Asimismo, el R^2 ajustado fue de 0.9761, valor muy cercano al coeficiente de determinación. La diferencia de 0.0025 entre ambos indicadores demuestra que la capacidad explicativa del modelo se mantiene después de considerar el número de variables independientes y el tamaño de la muestra. Por consiguiente, no se evidencia una reducción importante del ajuste como consecuencia del número de predictores utilizados.

La prueba de significancia global presentó un estadístico F de 388.5 y una probabilidad asociada de 9.41×10^{-41} , considerablemente inferior al nivel de significancia establecido ($\alpha=0.05$). En consecuencia, se rechaza la hipótesis nula de que todos los coeficientes de las variables independientes sean simultáneamente iguales a cero. Esto permite concluir que el conjunto de parámetros operativos y geomecánicos explica significativamente la variación de la vida útil del shank.

Los coeficientes estimados para cada variable independiente se presentan en la Tabla 14.

Tabla 14.

Coefficientes estimados del modelo de regresión lineal múltiple para el shank

Variable	Coefficiente	Error estándar	Estadístico t	Valor p
Intercepto	3628.323	51.028	71.104	<0.001
Presión de percusión	-1060.940	57.144	-18.566	<0.001
Presión de rotación	-763.927	59.364	-12.868	<0.001
Presión de avance	-810.152	58.332	-13.889	<0.001
Presión de agua	446.779	52.470	8.515	<0.001
Presión de aire	351.669	53.881	6.527	<0.001
RMR	-860.600	58.438	-14.727	<0.001

Nota. Elaboración propia.

De acuerdo con los resultados obtenidos, la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR presentaron valores de $p < 0.001$, inferiores al nivel de significancia de 0.05. Por lo tanto, todas las variables independientes muestran una asociación estadísticamente significativa con la vida útil del shank, manteniendo constantes los demás parámetros del modelo.

La presión de percusión presentó un coeficiente de -1060.940 y un estadístico t de -18.566; la presión de rotación obtuvo un coeficiente de -763.927 y un estadístico t de -12.868; mientras que la presión de avance registró un coeficiente de -810.152 y un estadístico t de -13.889. Estos coeficientes negativos indican relaciones inversas con la vida útil estimada del shank.

La presión de agua y la presión de aire presentaron coeficientes positivos de 446.779 y 351.669, respectivamente, lo que representa relaciones directas con la vida útil estimada. Por su parte, el RMR presentó un coeficiente de -860.600 , correspondiente a una relación inversa dentro del modelo. Debido al escalamiento efectuado mediante StandardScaler, estos coeficientes deben interpretarse respecto de cambios de una desviación estándar en cada variable, manteniendo constantes las demás.

Finalmente, el estadístico Durbin–Watson obtuvo un valor de 2.252, cercano al valor de referencia de 2. Este resultado indica que no existe evidencia importante de autocorrelación de primer orden en los residuos y constituye un indicador favorable para la validez del modelo de regresión lineal múltiple.

Adicionalmente, las pruebas de normalidad de los residuos presentaron probabilidades superiores a 0.05. La prueba Omnibus obtuvo un valor p de 0.641 y la prueba de Jarque–Bera alcanzó un valor p de 0.625. Por consiguiente, no existe evidencia estadística suficiente para rechazar el supuesto de normalidad de los residuos.

En conjunto, los resultados obtenidos permiten concluir que el modelo presenta un elevado nivel de ajuste, significancia estadística global y una adecuada capacidad explicativa para estimar la vida útil del shank a partir de la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR.

4.3.3 Aplicación del modelo para la predicción de la vida útil del shank (Predecir.py)

Una vez entrenado y validado estadísticamente el modelo de regresión lineal múltiple, se procedió a evaluar su aplicación mediante el script Predecir.py, cuyo

propósito es estimar la vida útil del shank a partir de valores específicos de los parámetros operativos y geomecánicos.

Para ello, el programa carga automáticamente el modelo previamente entrenado (linear_regression.joblib) y el objeto de escalamiento (scaler.joblib). De este modo, los datos ingresados son transformados utilizando los mismos parámetros de estandarización empleados durante el entrenamiento. Este procedimiento evita inconsistencias y garantiza que los datos sean procesados bajo las mismas condiciones estadísticas utilizadas para construir el modelo.

Como ejemplo de aplicación, se ingresaron los valores presentados en la Tabla 15.

Tabla 15

Parámetros operativos utilizados para la predicción de la vida útil del shank

Variable	Valor
Presión de percusión (bar)	190.0
Presión de rotación (bar)	45.0
Presión de avance (bar)	75.0
Presión de agua (bar)	8.0
Presión de aire (bar)	6.5
RMR	55.0

Nota. Elaboración propia.

Una vez procesados estos datos, el modelo estimó una vida útil del shank de 4026.11 m.

El resultado obtenido se muestra en la Figura 24.

Figura 24

Predicción de la vida útil del shank mediante el modelo de regresión lineal múltiple.

```

=====
PREDICCIÓN
=====
Presión Percusión : 190.0
Presión Rotación  : 45.0
Presión Avance    : 75.0
Presión Agua      : 8.0
Presión Aire      : 6.5
RMR               : 55.0
-----
Vida útil estimada : 4026.11
=====

```

Nota. Elaboración propia.

De acuerdo con la predicción realizada, bajo condiciones de 190.0 bar de presión de percusión, 45.0 bar de presión de rotación, 75.0 bar de presión de avance, 8.0 bar de presión de agua, 6.5 bar de presión de aire y un macizo rocoso con RMR de 55.0, el modelo estima que el shank alcanzará una vida útil aproximada de 4026.11 m antes de requerir su reemplazo.

Esta capacidad predictiva constituye una herramienta de apoyo para la planificación del mantenimiento preventivo, la programación de la reposición de componentes y la gestión de inventarios. Su aplicación permite anticipar el desgaste del shank y optimizar los costos relacionados con la adquisición, almacenamiento y utilización de los aceros de perforación.

Asimismo, el modelo permite efectuar estimaciones de manera inmediata mediante la modificación de los valores de entrada correspondientes a la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. De esta manera, el personal de operaciones o mantenimiento puede evaluar diferentes escenarios de trabajo y estimar anticipadamente la vida útil esperada del shank sin necesidad de volver a entrenar el modelo, siempre que los valores ingresados se encuentren dentro de los rangos considerados durante su desarrollo.

4.4 Desarrollo del Modelo 2: Coupling

4.4.1 Resultados del entrenamiento y evaluación del modelo de regresión lineal múltiple para el coupling (Entrenamiento.py)

Una vez preparado el conjunto de datos correspondiente al coupling, se procedió al entrenamiento del modelo de regresión lineal múltiple mediante la biblioteca Scikit-learn de Python. Para ello, se utilizaron como variables independientes la presión de

percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR, mientras que la variable dependiente fue la vida útil del coupling.

Previamente al entrenamiento, el conjunto de datos fue dividido en un 80 % para entrenamiento y un 20 % para prueba. Posteriormente, se aplicó el método StandardScaler para estandarizar las variables independientes, utilizando únicamente los parámetros calculados a partir del conjunto de entrenamiento. Este procedimiento evita la transferencia de información del conjunto de prueba hacia el entrenamiento y contribuye a evaluar la capacidad predictiva del modelo frente a datos no utilizados durante su construcción.

Figura 25

Resultado de la ejecución del código para el coupling

```
Intercepto:
[5060.57230769]

Coeficientes:
[[ 7506.46713659 -40.37726299 -4873.44776376 1220.27275878
 8851.59120922 -4659.33672132]]

=====
EVALUACIÓN DEL MODELO
=====
R² : 0.9760
MAE : 435.2044
RMSE : 557.2737
=====
```

Nota. Elaboración propia.

Como resultado del entrenamiento, se obtuvo un intercepto de 5060.5723 y los coeficientes correspondientes a las seis variables independientes. El modelo de regresión lineal múltiple quedó expresado de la siguiente manera:

$$\begin{aligned} \text{Vida}_{\text{Coupling}} = & 5060.5723 + 7506.4671(\text{Presión de percusión}) \\ & - 40.3773(\text{Presión de rotación}) - 4873.4478(\text{Presión de avance}) \\ & + 1220.2728(\text{Presión de agua}) + 8851.5912(\text{Presión de aire}) \\ & - 4659.3367(\text{RMR}) \end{aligned}$$

El intercepto representa el valor estimado de la vida útil del coupling cuando todas las variables independientes estandarizadas toman el valor de cero, es decir, cuando se encuentran en sus respectivos valores medios del conjunto de entrenamiento.

Los coeficientes asociados a cada variable representan su contribución dentro de la estimación de la vida útil del coupling, manteniendo constantes las demás variables. Los coeficientes positivos de la presión de percusión, presión de agua y presión de aire indican relaciones directas con la vida útil estimada. En cambio, los coeficientes negativos de la presión de rotación, presión de avance y RMR indican relaciones inversas.

Debido a que las variables independientes fueron estandarizadas mediante StandardScaler, los coeficientes representan el cambio esperado en la vida útil del coupling ante el incremento de una desviación estándar en cada predictor, manteniendo constantes las demás variables. Por tanto, no deben interpretarse como cambios producidos por el aumento de una unidad en las escalas originales de medición.

Posteriormente, el modelo fue evaluado utilizando el conjunto de prueba. Los indicadores de desempeño obtenidos se presentan en la **Tabla 16**.

Tabla 16

Indicadores de desempeño del modelo para la vida útil del coupling.

Indicador	Valor
R ²	0.9760
MAE	435.2044
RMSE	557.2737

Nota. Elaboración propia.

El coeficiente de determinación obtenido fue de $(R^2=0.9760)$, lo que indica que el modelo explica aproximadamente el 97.60 % de la variabilidad observada en la vida útil del coupling dentro del conjunto de prueba. Este resultado evidencia una elevada

capacidad predictiva conjunta de la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR.


Por otra parte, el Error Absoluto Medio (MAE) fue de 435.2044, lo que significa que las predicciones realizadas por el modelo difieren, en promedio, aproximadamente 435.20 unidades de vida útil respecto de los valores reales observados.

Asimismo, la Raíz del Error Cuadrático Medio (RMSE) alcanzó un valor de 557.2737. Esta métrica penaliza con mayor intensidad las predicciones que presentan errores elevados y permite evaluar la precisión global del modelo. Aunque el RMSE es superior al MAE, la diferencia entre ambos indicadores no evidencia un predominio marcado de errores excepcionalmente grandes en las predicciones realizadas.

En conjunto, los resultados muestran que el modelo de regresión lineal múltiple desarrollado para estimar la vida útil del coupling presenta un elevado desempeño predictivo. Por consiguiente, puede constituir una herramienta de apoyo para la planificación del mantenimiento preventivo, la programación de la reposición y la gestión de los componentes de la columna de perforación en la Unidad Minera San Cristóbal.

Figura 26

Comparación entre la vida útil real y la vida útil predicha para el modelo del coupling



Nota. Elaboración propia.

4.4.2 Validación estadística del modelo (Análisis_Statsmodels.py)

Con el propósito de verificar la validez estadística del modelo desarrollado para estimar la vida útil del coupling, se empleó la biblioteca Statsmodels de Python. Esta biblioteca permite obtener un análisis detallado del modelo de regresión lineal múltiple, proporcionando indicadores relacionados con la calidad del ajuste, la significancia global del modelo, la significancia individual de los coeficientes y el comportamiento de los residuos.

La **Figura 27** presenta el resumen estadístico obtenido mediante la función `summary()`.

Figura 27

Resumen estadístico del modelo de regresión lineal múltiple para la vida útil del coupling

```
=====
RESUMEN DEL MODELO
=====
                        OLS Regression Results
=====
Dep. Variable:          Vida_Coupling      R-squared:                0.965
Model:                  OLS                Adj. R-squared:           0.958
Method:                 Least Squares       F-statistic:             145.9
Date:                   Tue, 25 Aug 2026    Prob (F-statistic):      8.19e-22
Time:                   17:05:59           Log-Likelihood:          -303.40
No. Observations:       39                AIC:                     620.8
Df Residuals:           32                BIC:                     632.4
Df Model:               6
Covariance Type:        nonrobust
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	5060.5723	102.270	49.482	0.000	4852.255	5268.889
x1	7506.4671	1426.728	5.261	0.000	4600.317	1.04e+04
x2	-40.3773	104.171	-0.388	0.701	-252.567	171.813
x3	-4873.4478	901.903	-5.404	0.000	-6710.564	-3036.331
x4	1220.2728	910.787	1.340	0.190	-634.941	3075.486
x5	8851.5912	1198.459	7.386	0.000	6410.410	1.13e+04
x6	-4659.3367	1667.860	-2.794	0.009	-8056.657	-1262.016

```
=====
Omnibus:                8.846      Durbin-Watson:            2.092
Prob(Omnibus):           0.012      Jarque-Bera (JB):         7.776
Skew:                    0.911      Prob(JB):                 0.0205
Kurtosis:                4.212      Cond. No.:                45.6
=====
Notes:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
=====
```

Nota. Elaboración propia.

El modelo obtuvo un coeficiente de determinación R^2 de 0.9647, lo que indica que el 96.47 % de la variabilidad observada en la vida útil del coupling es explicada conjuntamente por la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. Este resultado evidencia un elevado nivel de ajuste entre los valores observados y los estimados.

Asimismo, el R^2 ajustado fue de 0.9581, valor próximo al coeficiente de determinación. La diferencia de 0.0066 entre ambos indicadores muestra que la capacidad explicativa del modelo se mantiene después de considerar el número de variables independientes y el tamaño de la muestra.

La prueba de significancia global presentó un estadístico F de 145.9 y una probabilidad asociada de 8.19×10^{-22} , considerablemente inferior al nivel de significancia establecido $\alpha = 0.05$. En consecuencia, se rechaza la hipótesis nula de que todos los coeficientes de las variables independientes sean simultáneamente iguales a cero. Por lo tanto, el conjunto de parámetros operativos y geomecánicos explica significativamente la variación de la vida útil del coupling.

Los coeficientes estimados para las variables independientes se presentan en la **Tabla 17**.

Tabla 17

Coefficientes estimados del modelo de regresión lineal múltiple para el coupling.

Variable	Coefficiente	Error estándar	Estadístico t	Valor p
Intercepto	5060.572	102.270	49.482	<0.001
Presión de percusión	7506.467	1426.728	5.261	<0.001
Presión de rotación	-40.377	104.171	-0.388	0.701
Presión de avance	-4873.448	901.903	-5.404	<0.001
Presión de agua	1220.273	910.787	1.340	0.190
Presión de aire	8851.591	1198.459	7.386	<0.001
RMR	-4659.337	1667.860	-2.794	0.009

Nota. Elaboración propia.

De acuerdo con los resultados obtenidos, la presión de percusión, presión de avance, presión de aire y RMR presentaron valores de $p < 0.05$. En consecuencia, estas variables muestran una asociación estadísticamente significativa con la vida útil del coupling, manteniendo constantes los demás parámetros del modelo.

La presión de percusión presentó un coeficiente positivo de 7506.467 y un valor $p < 0.001$, mientras que la presión de aire obtuvo un coeficiente positivo de 8851.591 y un valor $p < 0.001$. Estos resultados representan relaciones directas con la vida útil estimada del coupling. Por su parte, la presión de avance presentó un coeficiente de -4873.448 y un valor $p < 0.001$, mientras que el RMR registró un coeficiente de

-4659.337 y un valor $p=0.009$, evidenciando relaciones inversas estadísticamente significativas.

La presión de rotación presentó un coeficiente de -40.377 y un valor $p=0.701$, superior al nivel de significancia de 0.05 . Asimismo, la presión de agua obtuvo un coeficiente de 1220.273 y un valor $p=0.190$. Por tanto, considerando simultáneamente las demás variables independientes, no existe evidencia estadística suficiente para afirmar que sus coeficientes individuales sean diferentes de cero en el modelo del coupling.

En cuanto a la independencia de los residuos, el estadístico Durbin-Watson obtuvo un valor de 2.092 , próximo al valor de referencia de 2 . Este resultado indica que no existe evidencia importante de autocorrelación de primer orden en los residuos y constituye un indicador favorable para el modelo.

Las pruebas de normalidad, en cambio, presentaron probabilidades inferiores a 0.05 . La prueba Omnibus obtuvo un valor $p=0.012$, mientras que la prueba de Jarque-Bera presentó un valor $p=0.0205$. Estos resultados indican evidencia de desviación respecto del supuesto de normalidad de los residuos, asociada a una asimetría positiva de 0.911 y una curtosis de 4.212 . En consecuencia, las pruebas de significancia individual deben interpretarse considerando esta limitación.

En conjunto, el modelo presenta un elevado nivel de ajuste y significancia estadística global para estimar la vida útil del coupling. No obstante, la interpretación individual de los coeficientes debe efectuarse con cautela debido a la falta de significancia de la presión de rotación y la presión de agua, la desviación del supuesto de normalidad de los residuos y la posible dependencia entre algunas variables independientes.

4.4.3 Aplicación del modelo para la predicción de la vida útil del coupling

(Predecir.py)

Una vez entrenado y validado estadísticamente el modelo de regresión lineal múltiple para el coupling, se procedió a evaluar su aplicación mediante el script Predecir.py, cuyo propósito es estimar la vida útil del componente a partir de valores específicos de los parámetros operativos y geomecánicos.

Para realizar la predicción, el programa carga automáticamente el modelo previamente entrenado (linear_regression_coupling.joblib) y el objeto de escalamiento (scaler_coupling.joblib). Este último utiliza los mismos parámetros calculados durante la etapa de entrenamiento. De esta manera, los datos ingresados son transformados bajo las mismas condiciones estadísticas utilizadas para construir el modelo, asegurando la consistencia del procedimiento de predicción.

Como ejemplo de aplicación, se ingresaron los parámetros presentados en la **Tabla 18**.

Tabla 18

Parámetros operativos utilizados para la predicción de la vida útil del coupling

Variable	Valor
Presión de percusión (bar)	190.0
Presión de rotación (bar)	45.0
Presión de avance (bar)	75.0
Presión de agua (bar)	10.0
Presión de aire (bar)	7.5
RMR	60.0

Nota. Elaboración propia.

Una vez estandarizados y procesados estos datos, el modelo estimó una vida útil del coupling de 9217.99 m.

El resultado obtenido se muestra en la **Figura 28**.

Figura 28

Predicción de la vida útil del coupling

```
=====
PREDICCIÓN
=====
Presión Percusión : 190.0
Presión Rotación  : 45
Presión Avance    : 75.0
Presión Agua      : 10.0
Presión Aire      : 7.5
RMR               : 60.0
=====
Vida útil estimada : 9217.99
=====
```

Nota. Elaboración propia.

De acuerdo con la predicción realizada, bajo condiciones de 190.0 bar de presión de percusión, 45.0 bar de presión de rotación, 75.0 bar de presión de avance, 10.0 bar de presión de agua, 7.5 bar de presión de aire y un macizo rocoso con RMR de 60.0, el modelo estima que el coupling alcanzará una vida útil aproximada de 9217.99 m.

Esta capacidad predictiva constituye una herramienta de apoyo para la programación del mantenimiento preventivo y la planificación de la reposición de los componentes de la columna de perforación. Al estimar anticipadamente la vida útil del coupling, es posible mejorar la gestión del inventario de repuestos, disminuir el riesgo de paradas no programadas y favorecer la continuidad de las actividades de perforación en la Unidad Minera San Cristóbal.

Asimismo, el script permite evaluar diferentes escenarios operativos mediante la modificación de los valores correspondientes a la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR, sin necesidad de volver a entrenar el modelo. Sin embargo, las predicciones deben realizarse preferentemente con valores comprendidos dentro de los rangos utilizados durante el entrenamiento y deben complementarse con el seguimiento del desgaste observado en campo.

4.5 Desarrollo del Modelo 3: Barra

4.5.1 Entrenamiento y evaluación del modelo de regresión lineal múltiple para la barra (Entrenamiento.py)

Una vez preparado el conjunto de datos correspondiente a la barra de perforación, se procedió al entrenamiento del modelo de regresión lineal múltiple mediante la biblioteca scikit-learn de Python. Para ello se utilizaron como variables independientes la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y el Índice de RMR, mientras que la variable dependiente fue la vida útil de la barra.

Previamente al entrenamiento, el conjunto de datos fue dividido en un 80 % para entrenamiento y un 20 % para prueba, aplicándose posteriormente el método StandardScaler para estandarizar las variables independientes utilizando únicamente los parámetros calculados a partir del conjunto de entrenamiento.

Figura 29

Resultado de la ejecución del código para la barra

```
Intercepto:
[3100.19116667]

Coeficientes:
[[ -746.09275414  -20.11766771  -638.29681286  -331.37457429
  -1099.56743874  1425.90455404]]

=====
EVALUACIÓN DEL MODELO
=====
R²   : 0.9288
MAE  : 247.5344
RMSE : 365.3333
=====
```

Nota. Elaboración propia.

Como resultado del entrenamiento se obtuvo el siguiente modelo de regresión lineal múltiple:

$$\begin{aligned} \text{Vida}_{\text{Barra}} = & 3100.1912 - 746.0928(\text{Presión de percusión}) \\ & - 20.1177(\text{Presión de rotación}) - 638.2968(\text{Presión de avance}) \\ & - 331.3746(\text{Presión de agua}) - 1099.5674(\text{Presión de aire}) \\ & + 1425.9046(\text{RMR}) \end{aligned}$$

El intercepto del modelo fue de 3100.191, mientras que los coeficientes estimados representan la influencia relativa de cada una de las variables independientes sobre la vida útil de la barra. Debido a que las variables fueron previamente estandarizadas mediante StandardScaler, dichos coeficientes corresponden al efecto de cada predictor en la escala estandarizada y no deben interpretarse directamente en sus unidades originales.

Posteriormente, el modelo fue evaluado utilizando el conjunto de prueba, obteniéndose los indicadores de desempeño que se presentan en la Tabla 19.

Tabla 19

Indicadores de desempeño del modelo de regresión lineal múltiple para la vida útil de la barra.

Indicador	Valor
R ²	0.9288
MAE	247.5344
RMSE	365.333

Nota. Elaboración propia.

El coeficiente de determinación obtenido fue de R²=0.9288, lo que indica que el modelo explica aproximadamente el 92.88 % de la variabilidad observada en la vida útil de la barra dentro del conjunto de prueba. Este resultado evidencia una elevada capacidad predictiva conjunta de la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR.


Por otra parte, el Error Absoluto Medio (MAE) fue de 247.5344 m, lo que significa que las predicciones realizadas por el modelo difieren, en promedio, aproximadamente 247.53 m respecto de los valores reales observados.

Asimismo, la Raíz del Error Cuadrático Medio (RMSE) alcanzó un valor de 365.3333 m. Esta métrica penaliza con mayor intensidad las predicciones que presentan errores elevados y permite evaluar la precisión global del modelo. El valor del RMSE superior al MAE indica que algunas observaciones presentan errores mayores que el promedio; sin embargo, el coeficiente de determinación obtenido muestra que el modelo conserva una elevada capacidad para explicar la variabilidad de la vida útil de la barra.

En conjunto, los resultados evidencian que el modelo de regresión lineal múltiple desarrollado para estimar la vida útil de la barra de perforación presenta un elevado nivel de ajuste y una adecuada capacidad predictiva. Por consiguiente, puede constituir una herramienta de apoyo para la planificación del mantenimiento preventivo, la programación del reemplazo de componentes y la gestión de las operaciones de perforación en la Unidad Minera San Cristóbal.

Figura 30

Comparación entre la vida útil real y la vida útil predicha para el modelo de la barra



Nota. Elaboración propia.

4.5.2 Validación estadística del modelo (Análisis_Statsmodels.py)

Con el propósito de verificar la validez estadística del modelo desarrollado para estimar la vida útil de la barra de perforación, se empleó la biblioteca Statsmodels de Python. Esta biblioteca permite realizar un análisis estadístico detallado del modelo de regresión lineal múltiple, proporcionando indicadores sobre la calidad del ajuste, la significancia de los coeficientes y el cumplimiento de los principales supuestos estadísticos.

La **Figura 31** presenta el resumen estadístico obtenido mediante la función `summary()`.

Figura 31

Resumen estadístico del modelo de regresión lineal múltiple para la vida útil de la barra.

RESUMEN DEL MODELO						
=====						
OLS Regression Results						
=====						
Dep. Variable:	Vida_Barra	R-squared:	0.971			
Model:	OLS	Adj. R-squared:	0.968			
Method:	Least Squares	F-statistic:	296.7			
Date:	Tue, 25 Aug 2026	Prob (F-statistic):	6.15e-39			
Time:	18:17:10	Log-Likelihood:	-410.72			
No. Observations:	60	AIC:	835.4			
Df Residuals:	53	BIC:	850.1			
Df Model:	6					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]

const	3100.1912	31.225	99.286	0.000	3037.562	3162.820
x1	-746.0928	165.891	-4.497	0.000	-1078.828	-413.358
x2	-20.1177	31.837	-0.632	0.530	-83.975	43.740
x3	-638.2968	105.973	-6.023	0.000	-850.851	-425.742
x4	-331.3746	268.513	-1.234	0.223	-869.944	207.195
x5	-1099.5674	330.855	-3.323	0.002	-1763.179	-435.956
x6	1425.9046	463.300	3.078	0.003	496.643	2355.166
=====						
Omnibus:	29.550	Durbin-Watson:	2.199			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	56.817			
Skew:	1.634	Prob(JB):	4.60e-13			
Kurtosis:	6.471	Cond. No.	37.5			
=====						

Nota. Elaboración propia.

El modelo obtuvo un coeficiente de determinación R^2 de 0.9711, lo que indica que el 97.11 % de la variabilidad observada en la vida útil de la barra es explicada conjuntamente por la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. Este resultado evidencia un elevado nivel de ajuste entre los valores observados y los estimados.

Asimismo, el R^2 ajustado fue de 0.9678, valor próximo al coeficiente de determinación. La diferencia de 0.0033 entre ambos indicadores demuestra que la capacidad explicativa del modelo se mantiene después de considerar el número de variables independientes y las observaciones analizadas.

La prueba de significancia global presentó un estadístico F de 296.7 y una probabilidad asociada de 6.15×10^{-39} , considerablemente inferior al nivel de

significancia establecido $\alpha = 0.05$. En consecuencia, se rechaza la hipótesis nula de que todos los coeficientes de las variables independientes sean simultáneamente iguales a cero. Por lo tanto, el conjunto de parámetros operativos y geomecánicos explica significativamente la variación de la vida útil de la barra.

Los coeficientes estimados para las variables independientes se presentan en la **Tabla 20**.

Tabla 20

Coefficientes estimados del modelo de regresión lineal múltiple para la barra

Variable	Coefficiente	Error estándar	Estadístico t	Valor p
Intercepto	3100.191	31.225	99.286	<0.001
Presión de percusión	-746.093	165.891	-4.497	<0.001
Presión de rotación	-20.118	31.837	-0.632	0.530
Presión de avance	-638.297	105.973	-6.023	<0.001
Presión de agua	-331.375	268.513	-1.234	0.223
Presión de aire	-1099.567	330.855	-3.323	0.002
RMR	1425.905	463.300	3.078	0.003

Nota. Elaboración propia.

De acuerdo con los resultados obtenidos, la presión de percusión, presión de avance, presión de aire y RMR presentaron valores de $p < 0.05$. En consecuencia, estas variables muestran una asociación estadísticamente significativa con la vida útil de la barra, manteniendo constantes los demás parámetros del modelo.

La presión de percusión presentó un coeficiente de -746.093 y un valor $p < 0.001$; la presión de avance obtuvo un coeficiente de -638.297 y un valor $p < 0.001$; mientras que la presión de aire registró un coeficiente de -1099.567 y un valor $p = 0.002$. Los signos negativos representan relaciones inversas con la vida útil estimada de la barra. Por su parte, el RMR presentó un coeficiente positivo de 1425.905 y un valor $p = 0.003$, lo que representa una relación directa estadísticamente significativa dentro del modelo.

La presión de rotación presentó un coeficiente de -20.118 y un valor $p = 0.530$, superior al nivel de significancia de 0.05. Asimismo, la presión de agua obtuvo un

coeficiente de -331.375 y un valor $p=0.223$. Por consiguiente, al considerar simultáneamente las demás variables independientes, no existe evidencia estadística suficiente para afirmar que los coeficientes individuales de la presión de rotación y la presión de agua sean diferentes de cero en el modelo de la barra.

La presión de rotación y la presión de agua se conservaron debido a su importancia operacional en el proceso de perforación y porque forman parte de los parámetros establecidos en el planteamiento metodológico de la investigación. Mantener la misma estructura de variables en los modelos también permite realizar comparaciones homogéneas entre los componentes de la columna de perforación. Sin embargo, sus coeficientes individuales deben interpretarse con cautela y no como evidencia concluyente de un efecto sobre la vida útil de la barra.

Respecto de la independencia de los residuos, el estadístico Durbin–Watson obtuvo un valor de 2.199, cercano al valor de referencia de 2. Este resultado indica que no existe evidencia importante de autocorrelación de primer orden entre los residuos y constituye un indicador favorable para el modelo.

Las pruebas de normalidad, en cambio, presentaron probabilidades inferiores a 0.05. La prueba Omnibus obtuvo un valor $p<0.001$, mientras que la prueba de Jarque-Bera presentó una probabilidad de 4.60×10^{-13} . Estos resultados evidencian una desviación respecto del supuesto de normalidad de los residuos, caracterizada por una asimetría positiva de 1.634 y una curtosis de 6.471. En consecuencia, las pruebas de significancia individual deben interpretarse considerando esta limitación.

El número de condición fue de 37.5. Al ser superior a 30, este indicador sugiere una posible multicolinealidad importante entre algunas variables independientes. Esta dependencia puede dificultar la separación de sus efectos individuales y aumentar la

incertidumbre de determinados coeficientes, particularmente aquellos correspondientes a la presión de rotación y la presión de agua.

En conjunto, el modelo presenta un elevado nivel de ajuste y significancia estadística global para estimar la vida útil de la barra de perforación. No obstante, la interpretación individual de los coeficientes debe efectuarse con cautela debido a la falta de significancia estadística de la presión de rotación y la presión de agua, la desviación del supuesto de normalidad de los residuos y la posible dependencia entre algunas variables independientes.

4.5.3 Aplicación del modelo para la predicción de la vida útil de la barra (Predecir.py)

Una vez entrenado y validado estadísticamente el modelo de regresión lineal múltiple para la barra de perforación, se procedió a evaluar su capacidad predictiva mediante el script Predecir.py. Este programa carga el modelo previamente entrenado y el objeto StandardScaler, aplica el mismo proceso de escalamiento a un nuevo conjunto de variables operativas y genera la estimación correspondiente de la vida útil de la barra.

Para esta evaluación se utilizaron como datos de entrada una presión de percusión de 185.0 bar, una presión de rotación de 45.0 bar, una presión de avance de 75.0 bar, una presión de agua de 10.0 bar, una presión de aire de 7.5 bar y un macizo rocoso con RMR de 60.0.

Una vez estandarizados y procesados estos valores, el modelo estimó una vida útil de 4731.80 m para la barra de perforación.

Figura 32

Predicción de la vida útil de la barra mediante el modelo de regresión lineal múltiple.

```
=====
PREDICCIÓN
=====
Presión Percusión : 185.0
Presión Rotación  : 45.0
Presión Avance    : 75.0
Presión Agua      : 10.0
Presión Aire      : 7.5
RMR               : 60.0
-----
Vida útil estimada : 4731.80
=====
```

Nota. Elaboración propia.

Los resultados obtenidos demuestran que el modelo desarrollado permite estimar de manera inmediata la vida útil esperada de la barra de perforación a partir de un conjunto de parámetros operativos y geomecánicos. Esta capacidad predictiva constituye una herramienta de apoyo para la planificación del reemplazo de componentes, permitiendo anticipar el desgaste de la barra y optimizar la programación del mantenimiento preventivo.

4.6 Desarrollo del Modelo 4: Broca

4.6.1 Resultados del entrenamiento del modelo de regresión lineal múltiple para la broca (Entrenamiento.py)

Una vez preparado el conjunto de datos correspondiente a la broca de perforación, se procedió al entrenamiento del modelo de regresión lineal múltiple mediante la biblioteca scikit-learn de Python. Como variables independientes se utilizaron la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y la RMR, mientras que la variable dependiente correspondió a la vida útil de la broca.

Previamente al entrenamiento, el conjunto de datos fue dividido en un 80 % para entrenamiento y un 20 % para prueba. Posteriormente, se aplicó el método

StandardScaler para estandarizar las variables independientes utilizando únicamente los parámetros calculados a partir del conjunto de entrenamiento.

Durante el proceso de entrenamiento, el algoritmo estimó un intercepto de 250.2708 y los coeficientes asociados a las seis variables independientes.

Figura 33

Resultado de la ejecución del código para la broca

```
Intercepto:
[250.27075]

Coeficientes:
[[-0.20095689  0.1754164  0.18275787  3.26826154  1.1500145  31.29810021]]

=====
EVALUACIÓN DEL MODELO
=====
R²   : 0.9639
MAE  : 4.4071
RMSE : 6.0853
=====
```

Nota. Elaboración propia.

A partir del intercepto y los coeficientes estimados, el modelo de regresión lineal múltiple quedó expresado mediante la siguiente ecuación:

$$\begin{aligned} \text{Vida}_{\text{Broca}} = & 250.2708 - 0.2010(\text{Presión de percusión}) \\ & + 0.1754(\text{Presión de rotación}) + 0.1828(\text{Presión de avance}) \\ & + 3.2683(\text{Presión de agua}) + 1.1500(\text{Presión de aire}) \\ & + 31.2981(\text{RMR}) \end{aligned}$$

El intercepto representa la vida útil estimada de la broca cuando todas las variables independientes estandarizadas toman el valor de cero, es decir, cuando se encuentran en sus respectivos valores medios del conjunto de entrenamiento.


El signo de cada coeficiente representa la dirección de su relación con la vida útil estimada de la broca, manteniendo constantes las demás variables. La presión de percusión presentó un coeficiente negativo de -0.2010 , lo que representa una relación inversa. Por su parte, la presión de rotación, presión de avance, presión de agua,

presión de aire y RMR presentaron coeficientes positivos, correspondientes a relaciones directas dentro del modelo.

Debido a que las variables independientes fueron estandarizadas mediante StandardScaler, los coeficientes representan el cambio esperado en la vida útil de la broca ante el incremento de una desviación estándar en cada predictor, manteniendo constantes las demás variables. Por consiguiente, no deben interpretarse como cambios ocasionados por el aumento de una unidad en las escalas originales. La significancia estadística individual de los coeficientes será determinada mediante el análisis realizado con Statsmodels.

Figura 34

Comparación entre la vida útil real y la vida útil predicha para el modelo de la broca



Nota. Elaboración propia.

4.6.2 Validación estadística del modelo (Análisis_Statsmodels.py)

Con la finalidad de evaluar la validez estadística del modelo de regresión lineal múltiple desarrollado para la broca de perforación, se empleó la biblioteca Statsmodels de Python. Esta herramienta permitió estimar los coeficientes mediante el método de Mínimos Cuadrados Ordinarios (Ordinary Least Squares, OLS) y analizar la significancia estadística de cada variable independiente.

Figura 35

Resumen estadístico del modelo de regresión lineal múltiple para la vida útil de la broca.

```
=====
RESUMEN DEL MODELO
=====
                        OLS Regression Results
=====
Dep. Variable:          Vida_Broca      R-squared:                0.966
Model:                  OLS             Adj. R-squared:          0.963
Method:                 Least Squares   F-statistic:             345.0
Date:                   Tue, 25 Aug 2026 Prob (F-statistic):       1.81e-51
Time:                   21:12:43        Log-Likelihood:          -263.19
No. Observations:       80             AIC:                    540.4
Df Residuals:           73             BIC:                    557.0
Df Model:                6
Covariance Type:        nonrobust
=====
```

	coef	std err	t	P> t	[0.025	0.975]
const	250.2707	0.760	329.265	0.000	248.756	251.786
x1	-0.2010	1.484	-0.135	0.893	-3.159	2.757
x2	0.1754	0.770	0.228	0.821	-1.360	1.711
x3	0.1828	1.438	0.127	0.899	-2.683	3.048
x4	3.2683	1.138	2.873	0.005	1.001	5.536
x5	1.1500	1.780	0.646	0.520	-2.397	4.697
x6	31.2981	1.706	18.348	0.000	27.899	34.698

```
=====
Omnibus:                14.440      Durbin-Watson:            2.231
Prob(Omnibus):           0.001      Jarque-Bera (JB):         17.184
Skew:                    -0.875     Prob(JB):                  0.000186
Kurtosis:                 4.447     Cond. No.                  6.26
=====
```

Nota. Elaboración propia.

Los resultados muestran que el modelo alcanzó un coeficiente de determinación R^2 de 0.9659 y un R^2 ajustado de 0.9631. Esto indica que aproximadamente el 96.59 % de la variabilidad observada en la vida útil de la broca es explicada conjuntamente por la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR.

La diferencia de 0.0028 entre el R^2 y el R^2 ajustado evidencia que la capacidad explicativa del modelo se mantiene después de considerar el número de variables independientes y las observaciones analizadas.

De manera global, el modelo resultó estadísticamente significativo, con un estadístico F de 345.0 y una probabilidad asociada de (1.81×10^{-51}) , considerablemente inferior al nivel de significancia establecido ($\alpha = 0.05$). En consecuencia, se rechaza la hipótesis nula de que todos los coeficientes de las variables independientes sean simultáneamente iguales a cero. Por lo tanto, el conjunto de parámetros operativos y geomecánicos explica significativamente la variación de la vida útil de la broca.

Los coeficientes estimados y sus respectivos niveles de significancia se presentan en la **Tabla 21**.

Tabla 21

Coefficientes estimados del modelo de regresión lineal múltiple para la broca

Variable	Coefficiente	Error estándar	Estadístico t	Valor p
Intercepto	250.271	0.760	329.265	<0.001
Presión de percusión	-0.201	1.484	-0.135	0.893
Presión de rotación	0.175	0.770	0.228	0.821
Presión de avance	0.183	1.438	0.127	0.899
Presión de agua	3.268	1.138	2.873	0.005
Presión de aire	1.150	1.780	0.646	0.520
RMR	31.298	1.706	18.348	<0.001

Nota. Elaboración propia.

En cuanto a la significancia individual, la presión de agua presentó un coeficiente de 3.268 y un valor $p=0.005$, mientras que el RMR obtuvo un coeficiente de 31.298 y un valor $p<0.001$. Debido a que ambas probabilidades son inferiores a 0.05, estas variables muestran una asociación estadísticamente significativa y directa con la vida útil de la broca, manteniendo constantes los demás parámetros del modelo.

Por el contrario, la presión de percusión presentó un valor $p=0.893$; la presión de rotación, $p=0.821$; la presión de avance, $p=0.899$; y la presión de aire, $p=0.520$. Debido a que estos valores son superiores a 0.05, no existe evidencia estadística suficiente para afirmar que sus coeficientes individuales sean diferentes de cero cuando las demás variables se consideran simultáneamente.

Estas variables se conservaron debido a su importancia operacional en el proceso de perforación y porque forman parte de los parámetros establecidos en el planteamiento metodológico de la investigación. Mantener la misma estructura de variables también permite comparar los modelos correspondientes a los diferentes componentes de la columna de perforación. No obstante, sus coeficientes individuales deben interpretarse con cautela y no como evidencia concluyente de un efecto sobre la vida útil de la broca.

El estadístico Durbin-Watson presentó un valor de 2.231, cercano al valor de referencia de 2. Este resultado indica que no existe evidencia importante de autocorrelación de primer orden entre los residuos y constituye un indicador favorable para el modelo.

Las pruebas de normalidad presentaron resultados inferiores al nivel de significancia de 0.05. La prueba Omnibus obtuvo un estadístico de 14.440 y un valor $p=0.001$, mientras que la prueba de Jarque-Bera alcanzó un estadístico de 17.184 y un valor $p=0.000186$. Estos resultados evidencian una desviación respecto del supuesto de normalidad de los residuos, caracterizada por una asimetría negativa de -0.875 y una curtosis de 4.447.

La desviación del supuesto de normalidad no invalida automáticamente la capacidad predictiva observada en el conjunto de prueba; sin embargo, implica que las

pruebas de significancia, los intervalos de confianza y las conclusiones inferenciales deben interpretarse con cautela.

Por otro lado, el número de condición fue de 6.26. Al encontrarse por debajo de 10, este resultado no evidencia un problema importante de multicolinealidad general entre las variables independientes. Por consiguiente, la falta de significancia individual de algunos coeficientes no puede atribuirse directamente a una dependencia elevada entre los predictores a partir de este indicador.

En conjunto, el modelo presenta un elevado nivel de ajuste y significancia estadística global para estimar la vida útil de la broca. Sin embargo, la interpretación individual de los coeficientes debe considerar que únicamente la presión de agua y el RMR resultaron estadísticamente significativos y que los residuos presentan desviaciones respecto de una distribución normal.

4.6.3 Aplicación del modelo para la predicción de la vida útil de la broca (Predecir.py)

Una vez entrenado y validado estadísticamente el modelo de regresión lineal múltiple para la broca de perforación, se procedió a evaluar su capacidad predictiva mediante el script Predecir.py. Este programa carga el modelo previamente entrenado y el objeto StandardScaler, aplica el mismo proceso de escalamiento a un nuevo conjunto de variables operativas y genera la estimación correspondiente de la vida útil de la broca.

Para esta evaluación se utilizaron como datos de entrada una presión de percusión de 185.0 bar, una presión de rotación de 45.0 bar, una presión de avance de 75.0 bar, una presión de agua de 10.0 bar, una presión de aire de 7.5 bar y un macizo rocoso con RMR de 60.0. Una vez estandarizados y procesados estos valores, el modelo estimó una vida útil de 270.39 m para la broca de perforación.

Figura 36

Predicción de la vida útil de la broca mediante el modelo de regresión lineal múltiple.

```
=====
PREDICCIÓN
=====
Presión Percusión : 185.0
Presión Rotación  : 45.0
Presión Avance    : 75.0
Presión Agua      : 10.0
Presión Aire      : 7.5
RMR               : 60.0
-----
Vida útil estimada : 270.39
```

Nota. Elaboración propia.

Tabla 22

Predicción de la vida útil de la broca mediante el modelo de regresión lineal múltiple

Variable	Valor
Presión de percusión (bar)	185.0
Presión de rotación (bar)	45.0
Presión de avance (bar)	75.0
Presión de agua (bar)	10.0
Presión de aire (bar)	7.5
RMR	60.0
Vida útil estimada (m)	270.39

Nota. Elaboración propia.

Los resultados obtenidos demuestran que el modelo desarrollado permite estimar de manera rápida la vida útil esperada de la broca a partir de los parámetros operativos y geomecánicos registrados durante la perforación. Esta capacidad predictiva constituye una herramienta de apoyo para la planificación del reemplazo oportuno de las brocas, permitiendo anticipar su desgaste y optimizar las actividades de mantenimiento preventivo.

Asimismo, el procedimiento puede aplicarse a cualquier combinación de condiciones operativas registradas en campo, siempre que las variables de entrada

correspondan a aquellas utilizadas durante el entrenamiento del modelo. De esta manera, el algoritmo desarrollado puede incorporarse como una herramienta de apoyo para la gestión de la perforación en la Unidad Minera San Cristóbal, favoreciendo una mejor planificación operativa, una reducción de costos asociados al desgaste de herramientas y una mayor disponibilidad de los equipos de perforación.

4.7 Comparación de los cuatro modelos de regresión lineal múltiple

Con el propósito de evaluar el desempeño de los modelos desarrollados para cada uno de los componentes de la columna de perforación, se realizó una comparación de los indicadores de desempeño obtenidos durante el entrenamiento y la validación de cada modelo. La comparación considera el coeficiente de determinación (R^2), el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE), indicadores ampliamente utilizados para evaluar la precisión de modelos de regresión.

4.7.1 Comparación del desempeño predictivo de los modelos

La Tabla 23 presenta los principales indicadores obtenidos para cada uno de los cuatro modelos desarrollados.

Tabla 23


Comparación de los indicadores de desempeño de los modelos de regresión lineal múltiple.

Modelo	Variable dependiente	R^2	MAE	RMSE
Shank	Vida útil del shank	0.9236	415.98	452.23
Coupling	Vida útil del coupling	0.9760	435.20	557.27
Barra	Vida útil de la barra	0.9288	247.53	365.33
Broca	Vida útil de la broca	0.9639	4.40	6.08

Nota. Elaboración propia.

Figura 37

Comparación del coeficiente de determinación (R^2) de los cuatro modelos de regresión lineal múltiple.



Nota. Un valor más próximo a 1 indica una mayor capacidad del modelo para explicar la variabilidad observada en la variable dependiente.

Los cuatro modelos alcanzaron coeficientes de determinación superiores a 0.92, lo que evidencia una elevada capacidad para explicar la variabilidad de la vida útil de los diferentes componentes de la columna de perforación en sus respectivos conjuntos de prueba.

El modelo correspondiente al coupling obtuvo el mayor coeficiente de determinación, con un valor de $R^2=0.9760$, lo que indica que explica aproximadamente el 97.60 % de la variabilidad observada en su vida útil. Le sigue el modelo de la broca, con $R^2=0.9639$; posteriormente, el modelo de la barra, con $R^2=0.9288$; y finalmente, el modelo del shank, con $R^2=0.9236$.

Aunque el modelo del shank presentó el menor coeficiente de determinación entre los cuatro, explica el 92.36 % de la variabilidad observada, por lo que conserva una elevada capacidad predictiva. En consecuencia, las diferencias encontradas corresponden al nivel de ajuste alcanzado por cada modelo y no implican que alguno presente un desempeño insuficiente.

Respecto de los indicadores de error, sus valores absolutos no deben compararse directamente entre los cuatro modelos, debido a que las variables dependientes presentan diferentes escalas y rangos de vida útil. La broca posee una vida útil del orden de cientos de metros, mientras que el shank, coupling y barra alcanzan valores del orden de miles de metros. Por consiguiente, un MAE o RMSE numéricamente mayor no representa necesariamente una menor precisión, ya que su magnitud depende de la escala de la variable estimada.

En el modelo del shank se obtuvo un MAE de 415.98 m y un RMSE de 452.23 m; en el coupling, un MAE de 435.20 m y un RMSE de 557.27 m; en la barra, un MAE de 247.53 m y un RMSE de 365.33 m; y en la broca, un MAE de 4.40 m y un RMSE de 6.08 m. En todos los casos, el RMSE fue superior al MAE debido a que penaliza con mayor intensidad los errores de mayor magnitud.

En términos generales, los resultados obtenidos muestran que los cuatro modelos presentan una elevada capacidad explicativa y un desempeño predictivo adecuado para estimar la vida útil de los componentes de la columna de perforación bajo las condiciones representadas en los datos analizados. Su aplicación debe realizarse preferentemente dentro de los rangos operativos empleados durante el entrenamiento y complementarse con el control del desgaste observado en campo.

4.7.2 Comparación de las ecuaciones de regresión obtenidas

Como resultado del proceso de entrenamiento se obtuvieron cuatro ecuaciones de regresión lineal múltiple, una para cada componente de la columna de perforación. Estas ecuaciones permiten estimar la vida útil del shank, coupling, barra y broca a partir de la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR.

Tabla 24

Comparación de las ecuaciones de regresión lineal múltiple obtenidas.

Modelo	Ecuación de regresión
Shank	$\text{Vida}_{\text{Shank}} = 3628.3233 - 1060.9405(\text{Presión de percusión})$
	$- 763.9274(\text{Presión de rotación})$
	$- 810.1520(\text{Presión de avance})$
	$+ 446.7786(\text{Presión de agua})$
	$+ 351.6689(\text{Presión de aire}) - 860.6001(\text{RMR})$
Coupling	$\text{Vida}_{\text{Coupling}} = 5060.5723 + 7506.4671(\text{Presión de percusión})$
	$- 40.3773(\text{Presión de rotación})$
	$- 4873.4478(\text{Presión de avance})$
	$+ 1220.2728(\text{Presión de agua})$
	$+ 8851.5912(\text{Presión de aire}) - 4659.3367(\text{RMR})$
Barra	$\text{Vida}_{\text{Barra}} = 3100.1912 - 746.0928(\text{Presión de percusión})$
	$- 20.1177(\text{Presión de rotación})$
	$- 638.2968(\text{Presión de avance})$
	$- 331.3746(\text{Presión de agua})$
	$- 1099.5674(\text{Presión de aire}) + 1425.9046(\text{RMR})$

	$\text{Vida}_{\text{Broca}} = 250.2708 - 0.2010(\text{Presión de percusión})$
	$+ 0.1754(\text{Presión de rotación})$
Broca	$+ 0.1828(\text{Presión de avance})$
	$+ 3.2683(\text{Presión de agua})$
	$+ 1.1500(\text{Presión de aire}) + 31.2981(\text{RMR})$

Nota. Las ecuaciones expresan la relación estimada entre la vida útil del shank, coupling, barra y broca y las variables independientes correspondientes a la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. Debido a la aplicación de StandardScaler, los coeficientes corresponden a variables independientes estandarizadas; por ello, no representan cambios producidos por el incremento de una unidad en sus escalas originales.

La comparación de las ecuaciones evidencia que la dirección de las relaciones estimadas no es uniforme para todos los componentes. En el modelo del shank, la presión de percusión, presión de rotación, presión de avance y RMR presentan coeficientes negativos, mientras que la presión de agua y presión de aire muestran coeficientes positivos.

En el modelo del coupling, la presión de percusión, presión de agua y presión de aire presentan coeficientes positivos, mientras que la presión de rotación, presión de avance y RMR muestran coeficientes negativos. En el modelo de la barra, únicamente el RMR presenta un coeficiente positivo, mientras que las cinco presiones operativas registran coeficientes negativos. Finalmente, en el modelo de la broca, la presión de percusión presenta un coeficiente negativo, mientras que la presión de rotación, presión de avance, presión de agua, presión de aire y RMR muestran coeficientes positivos.

Estas diferencias reflejan que la respuesta de cada componente frente a las condiciones operativas y geomecánicas depende de su función mecánica, ubicación y mecanismo de desgaste dentro de la columna de perforación. Por esta razón, resulta adecuado disponer de un modelo específico para cada componente en lugar de emplear una sola ecuación general.

No obstante, el signo y la magnitud de los coeficientes deben interpretarse conjuntamente con sus valores de significancia estadística. En el modelo del shank, las seis variables presentaron significancia estadística. En el coupling y la barra, la presión de rotación y la presión de agua no fueron estadísticamente significativas. En el modelo de la broca, únicamente la presión de agua y el RMR alcanzaron significancia individual al nivel de 0.05. Por consiguiente, la presencia de un coeficiente positivo o negativo no demuestra por sí sola un efecto estadísticamente significativo sobre la vida útil del componente.

En conjunto, las ecuaciones obtenidas constituyen herramientas cuantitativas para estimar la vida útil de cada componente y apoyar la planificación del mantenimiento preventivo, la reposición de aceros de perforación y la gestión de inventarios en la Unidad Minera San Cristóbal.

CONCLUSIONES

1. Se desarrollaron cuatro modelos de regresión lineal múltiple para estimar la vida útil del shank, coupling, barra y broca en la Unidad Minera San Cristóbal. Los modelos utilizaron como variables independientes la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR. Los resultados obtenidos evidenciaron una elevada capacidad predictiva, por lo que los modelos constituyen herramientas de apoyo para la planificación del mantenimiento y el reemplazo oportuno de los componentes de la columna de perforación.
2. El modelo desarrollado para el shank obtuvo un coeficiente de determinación de $R^2=0.9236$ en el conjunto de prueba y un $R^2=0.9786$ en la validación estadística mediante OLS. Asimismo, presentó un MAE de 415.98 m y un RMSE de 452.24 m. Estos resultados indican que el modelo posee una elevada capacidad para estimar la vida útil del shank a partir de los parámetros operativos y geomecánicos considerados.
3. El modelo correspondiente al coupling alcanzó el mayor desempeño predictivo de los cuatro modelos, con un coeficiente de determinación de $R^2=0.9760$ en el conjunto de prueba y un $R^2=0.9647$ en la validación estadística. Además, obtuvo un MAE de 435.20 m y un RMSE de 557.27 m, evidenciando una elevada capacidad para estimar su vida útil bajo las condiciones operativas representadas en los datos analizados.
4. El modelo desarrollado para la barra obtuvo un coeficiente de determinación de $R^2=0.9288$ en el conjunto de prueba y un $R^2=0.9711$ en la validación estadística. También presentó un MAE de 247.53 m y un RMSE de 365.33 m. Estos resultados confirman que el modelo explica satisfactoriamente la

variabilidad observada y permite estimar la vida útil de la barra de perforación con una adecuada capacidad predictiva.

5. El modelo correspondiente a la broca presentó un coeficiente de determinación de $R^2=0.9639$ en el conjunto de prueba y un $R^2=0.9659$ en la validación estadística. Asimismo, alcanzó un MAE de 4.41 m y un RMSE de 6.09 m, demostrando una elevada capacidad para estimar la vida útil de la broca en función de la presión de percusión, presión de rotación, presión de avance, presión de agua, presión de aire y RMR.
6. La implementación mediante Scikit-learn y Statsmodels permitió construir, entrenar, evaluar y validar estadísticamente los cuatro modelos de regresión lineal múltiple. En todos los casos, la prueba global presentó un valor $p<0.001$, mientras que los coeficientes de determinación obtenidos en los conjuntos de prueba fueron superiores a 0.92. Sin embargo, la significancia individual varió entre los componentes: en el shank, las seis variables fueron estadísticamente significativas; en el coupling y la barra, la presión de rotación y la presión de agua no alcanzaron significancia; y en la broca, únicamente la presión de agua y el RMR resultaron significativos. Por consiguiente, los modelos presentan una elevada capacidad predictiva conjunta, aunque los coeficientes individuales deben interpretarse según los resultados estadísticos de cada componente.

RECOMENDACIONES

1. Se recomienda implementar un procedimiento estandarizado para el registro de la información de perforación, asegurando el seguimiento individual de cada acero de perforación durante todo su ciclo de vida útil. Asimismo, se debe registrar de manera independiente el metraje perforado por cada broca según su diámetro y por las rimadoras utilizadas.
2. Para mejorar el desempeño de futuros modelos de aprendizaje automático (Machine Learning), se recomienda registrar cada cambio de broca realizado durante la perforación, identificando el momento en que un mismo acero trabaja con diferentes diámetros de broca o con una rimadora. De igual manera, es conveniente contabilizar el metraje perforado asociado a cada combinación de barra-broca, ya que el desgaste de los componentes depende de las condiciones reales de operación. Esta información permitirá desarrollar modelos predictivos con mayor precisión y capacidad de generalización.
3. Se recomienda implementar sistemas sensores instalados en los equipos, que registren de forma continua parámetros como la presión de percusión, presión de avance, presión de agua, presión de aire y otros parámetros que son propios de equipo. El almacenamiento sistemático de esta información durante un periodo prolongado permitirá construir bases de datos robustas para el desarrollo de modelos más avanzados de inteligencia artificial, tales como Deep Learning, redes neuronales artificiales u otros algoritmos de aprendizaje automático, incrementando la precisión en la predicción de la vida útil de los componentes de la columna de perforación y fortaleciendo la toma de decisiones en la gestión del mantenimiento.

REFERENCIA BIBLIOGRÁFICA

- Alanya, H., & Sarmiento, V. (2025). Análisis de vida útil de aceros de perforación para reducir costos operativos en la Rampa 4200 de la Compañía Minera Ares Ayacucho s.a.c. – 2023 [Tesis de grado, Universidad Nacional de Huancavelica]. Repositorio institucional UNH <https://hdl.handle.net/20.500.14597/9381>
- Aligholi, S., Lashkaripour, G. R., Ghafoori, M., & Azali, S. T. (2017). Evaluating the Relationships Between NTNU/SINTEF Drillability Indices with Index Properties and Petrographic Data of Hard Igneous Rocks. *Rock Mechanics and Rock Engineering*, 50(11), 2929–2953. <https://doi.org/10.1007/s00603-017-1289-9>
- Atlas Copco. (2014). *Underground Mining, a global review of methods and practices* (1st edition). Editura Atlas Copco Rock Drills AB.
- Barrientos, I. (2022). Estudio técnico económico para el uso de barras de perforación en CIA Minera Aruntani—Unidad Santa Rosa, 2022. [Tesis de grado, Universidad Nacional de San Cristóbal de Huamanga]. Repositorio institucional UNSCH <http://repositorio.unsch.edu.pe/handle/UNSCH/4775>
- Boart Longyear. (2018). *Herramientas de perforación de martillo superior* (Boart Longyear).
- Capik, M., Yilmaz, A. O., & Yasar, S. (2017). Relationships between the drilling rate index and physicommechanical rock properties. *Bulletin of Engineering Geology and the Environment*, 76(1), 253–261. <https://doi.org/10.1007/s10064-016-0991-2>

- Carlisle, Scott. P. (2023). Underground Rock Mechanics and Ground Control. En P. Darling (Ed.), SME Underground Mining Handbook (pp. 381–416). Society for Mining, Metallurgy, and Exploration (SME).
- Chavez, R. (2024). Evaluación de pérdidas prematuras y su incidencia en el rendimiento de los accesorios de la columna de perforación en taladros largos en la UO San Cristóbal, CIA Minera Volcan S.A.A., 2023 [Tesis de grado, Universidad Nacional de San Cristóbal de Huamanga]. Repositorio institucional UNSCH
<https://repositorio.unsch.edu.pe/handle/20.500.14612/7752>
- Curasi, B., & Quispe, L. (2024). Evaluación de aceros de perforación para propuesta de consumo mensual, labores de avance, unidad minera Sotrami S. A., 2023 [Tesis de grado, Universidad Continental]. Repositorio institucional UC
<https://hdl.handle.net/20.500.12394/14927>
- Epiroc. (2022). Product catalogue—Tophammer equipment.
- Espinoza, O. (2018). Optimización de la rentabilidad en las operaciones de las vetas San Cristóbal Sur Oeste de la mina San Cristóbal de la Compañía Minera Volcan S.A.A. [Tesis de grado, Universidad Nacional Daniel Alcides Carrión]. Repositorio institucional UNDAC
<http://repositorio.undac.edu.pe/handle/undac/961>
- Famesa Explosivos S.A. (2019). Manual de perforación y Voladura (1.^a ed.). COSAS.
- Fattahi, H., & Ghaedi, H. (2024). Enhancing Rock Drilling Efficiency: A Comparative Analysis of DRI Estimation Models Using the RES Approach. Indian Geotechnical Journal, 54(4), 1438–1452. <https://doi.org/10.1007/s40098-023-00819-z>

- Flores, A., & Marinez, G. (2023). Control de las brocas y barras cónicas para incrementar la vida útil de los aceros de perforación EN Minera Aurífera Retamas S.A. [Tesis de grado, Universidad Continental]. Repositorio institucional UC <https://hdl.handle.net/20.500.12394/13751>
- Guo, H., Lin, L., Wu, J., Lv, Y., & Tong, C. (2024). Optimizing Driving Parameters of the Jumbo Drill Efficiently with XGBoost-DRWIACO Framework: Applied to Increase the Feed Speed. *Sensors*, 24(8), 2600. <https://doi.org/https://doi.org/10.3390/s24082600>
- Huamani, V. (2023). Evaluación de la columna de perforación, optimización de costos por metro perforado en CIA Minera Volcán S.A. Andaychagua 2021 [Tesis de grado, Universidad Nacional de San Cristóbal de Huamanga]. Repositorio institucional <http://repositorio.unsch.edu.pe/handle/UNSCH/6301>
- Jimeno, C. L., Jimeno, E. L., & Bermúdez, P. G. (2017). Manual de perforación, explosivos y voladuras: Minería y obras públicas. Grupo de Proyectos de Ingeniería, ETSI Minas y Energía, Universidad
- Karrari, S. S., Heidari, M., Hamidi, J. K., & Teshnizi, E. S. (2022). Estimation of drilling rate index values of granitic rocks with their mineralogical properties using different estimation models. *Arabian Journal of Geosciences*, 15(9), 856. <https://doi.org/10.1007/s12517-022-10120-7>
- Kwon, K.-B., Song, C.-H., Park, J.-Y., Oh, J.-Y., Lee, J.-W., & Cho, J.-W. (2014). Evaluation of drilling efficiency by percussion testing of a drill bit with new button arrangement. *International Journal of Precision Engineering and Manufacturing*, 15(6), 1063–1068. [https://doi.org/10.1007/s12541-014-0437-](https://doi.org/10.1007/s12541-014-0437-3)

- Nobahar, P., Shirani Faradonbeh, R., Almasi, S. N., & Bastami, R. (2024). Advanced AI-Powered Solutions for Predicting Blast-Induced Flyrock, Backbreak, and Rock Fragmentation. *Mining, Metallurgy & Exploration*, 41(4), 2099–2118. <https://doi.org/10.1007/s42461-024-01028-9>
- Osinergmin. (2017). Guía de criterios geomecánicos para diseño, construcción, supervisión y cierre de labores subterráneas. Osinergmin.
- Prieto, L., & Patiño, H. (2024). Reducción de costos operativos por consumo de aceros de perforación T38, utilizados para el minado por el método de explotación sub level stoping: Caso de estudio [Tesis de grado, Universidad Tecnológica del Perú]. Repositorio institucional UTP <https://hdl.handle.net/20.500.12867/10340>
- Quito, J., & Jaramillo, R. (2020). Análisis de la vida útil de aceros de perforación para evaluar costos operativos en galerías Compañía Minera San Cristobal S.A.A. [Tesis de grado, Universidad Continental]. Repositorio institucional UC <https://hdl.handle.net/20.500.12394/8523>
- Yenice, H. (2019). Determination of drilling rate index based on rock strength using regression analysis. *Anais da Academia Brasileira de Ciências*, 91(03), e20181095. <https://doi.org/https://doi.org/10.1590/0001-3765201920181095>
- Young, D. S. (2018). *Handbook of Regression Methods*. Chapman and Hall/CRC. <https://doi.org/10.1201/9781315154701>
- Zhang, Z.-X. (2016). *Rock Fracture and Blasting: Theory and Applications*. Butterworth-Heinemann. <https://doi.org/10.1016/C2014-0-01408-6>

V. ANEXOS

5.1 Anexo 1: Matriz de consistencia

Tabla 25

Matriz de consistencia

PROBLEMAS	OBJETIVOS	HIPÓTESIS	VARIABLES	MÉTODO DE INVESTIGACIÓN
PROBLEMA GENERAL ¿En qué medida los parámetros operativos de perforación permiten predecir la vida útil de la columna de perforación mediante un modelo de regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026? PROBLEMAS ESPECÍFICOS ¿Como se estima la vida útil del shank en función de los parámetros de perforación mediante regresión lineal múltiple? ¿Como se estima la vida útil de la barra en función de los parámetros de perforación mediante regresión lineal múltiple? ¿Como se estima la vida útil de la broca en función de los parámetros de perforación mediante regresión lineal múltiple? ¿Como se estima la vida útil del coupling en función de los parámetros de perforación mediante regresión lineal múltiple?	OBJETIVO GENERAL Estimar la vida útil de la columna de perforación en función de los parámetros de perforación mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026. OBJETIVOS ESPECÍFICOS - Estimar la vida útil del shank en función de los parámetros de perforación mediante regresión lineal múltiple. - Estimar la vida útil de la barra en función de los parámetros de perforación mediante regresión lineal múltiple. - Estimar la vida útil de la broca en función de los parámetros de perforación mediante regresión lineal múltiple. - Estimar la vida útil del coupling en función de los parámetros de perforación mediante regresión lineal múltiple. - Validar la precisión del modelo de regresión lineal múltiple mediante la comparación de la vida útil estimada frente a los datos reales de campo.	HIPÓTESIS GENERAL La vida útil de la columna de perforación se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026. HIPÓTESIS ESPECÍFICAS - La vida útil del shank se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple. - La vida útil de la barra se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple. - La vida útil de la broca se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple. - La vida útil del coupling se estima significativamente en función de los parámetros de perforación mediante regresión lineal múltiple.	VARIABLE INDEPENDIENTE X: Parámetros de perforación Dimensiones X1: Parámetros operativos X2: Parámetros geomecánicos X3: Parámetros geométricos VARIABLE DEPENDIENTE Y: Vida útil de la columna de perforación (m) Dimensiones Y1: Vida útil (metros perforados)	TIPO DE INVESTIGACIÓN Aplicada NIVEL DE INVESTIGACIÓN Explicativo DISEÑO No experimental – correlacional POBLACIÓN Todos los datos registros de perforación en la unidad minera MUESTRA Aceros de perforación como las shank, barras, brocas y coupling. TÉCNICA Análisis documental y revisión de registros INSTRUMENTO Registro de datos Registros fotográficos

5.1 Anexo 2: Código par el Shank

5.1.1 Entrenamiento.py

```
# =====  
# ENTRENAMIENTO DEL MODELO  
# =====  
  
import pandas as pd  
import matplotlib.pyplot as plt  
from sklearn.preprocessing import StandardScaler  
from sklearn.model_selection import train_test_split  
from sklearn.linear_model import LinearRegression  
from joblib import dump  
from sklearn.metrics import r2_score, mean_absolute_error,  
root_mean_squared_error  
  
# =====  
# Cargar datos  
# =====  
  
csv_data = "Datos/Datos_shank.xlsx"  
  
df = pd.read_excel(csv_data)  
  
# Seleccionar columnas  
  
df = df[["Vida_Shank", "Presion_Percusion", "Presion_Rotacion",  
"Presion_Avance", "Presion_Agua", "Presion_Aire", "RMR"]]  
  
# Eliminar datos faltantes  
  
df = df.dropna()  
  
# =====  
# Variables independientes y dependiente  
# =====  
  
y = df[["Vida_Shank"]]  
  
X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",  
"Presion_Agua", "Presion_Aire", "RMR"]]  
  
# =====  
# Dividir datos  
# =====  
  
X_train, X_test, y_train, y_test = train_test_split(  
    X,
```

```

    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento de variables
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

# IMPORTANTE:
# El conjunto de prueba utiliza los parámetros
# calculados con el conjunto de entrenamiento.

X_test = scaler.transform(X_test)

# =====
# Entrenar modelo
# =====

modelo = LinearRegression()

modelo.fit(X_train, y_train)

# =====
# Resultados
# =====

print("\nIntercepto:")

print(modelo.intercept_)

print("\nCoeficientes:")

print(modelo.coef_)

# =====
# EVALUACIÓN DEL MODELO
# =====

# Predicciones sobre el conjunto de prueba
y_pred = modelo.predict(X_test)

# Calcular métricas
r2 = r2_score(y_test, y_pred)

```

```

mae = mean_absolute_error(y_test, y_pred)

rmse = root_mean_squared_error(y_test, y_pred)

# Mostrar resultados

print("\n=====")
print("EVALUACIÓN DEL MODELO")
print("=====")

print(f"R²      : {r2:.4f}")
print(f"MAE      : {mae:.4f}")
print(f"RMSE      : {rmse:.4f}")

print("=====\\n")

# =====
# GRÁFICO: VALORES REALES VS. VALORES PREDICHOS
# =====

plt.figure(figsize=(9, 7))

# Dibujar los puntos
plt.scatter(
    y_test,
    y_pred,
    s=15,
    alpha=0.30,
    label="Observaciones"
)

# Límites del gráfico
valor_min = min(y_test.min().values[0], y_pred.min())
valor_max = max(y_test.max().values[0], y_pred.max())

# Línea de predicción perfecta
plt.plot(
    [valor_min, valor_max],
    [valor_min, valor_max],
    color="red",
    linestyle="--",
    linewidth=2,
    label="Predicción perfecta (y = x)"
)

# Título
plt.title(
    "Valores reales vs. valores predichos",
    fontsize=15,

```

```

        fontweight="bold"
    )

# Etiquetas
plt.xlabel(
    "Vida útil real",
    fontsize=12
)

plt.ylabel(
    "Vida útil predicha",
    fontsize=12
)

# Cuadro con métricas
texto = (
    f"R²    = {r2:.4f}\n"
    f"MAE    = {mae:.4f}\n"
    f"RMSE   = {rmse:.4f}"
)

plt.text(
    0.03,
    0.97,
    texto,
    transform=plt.gca().transAxes,
    fontsize=11,
    verticalalignment="top",
    bbox=dict(
        facecolor="white",
        edgecolor="black",
        alpha=0.85
    )
)

# Cuadrícula
plt.grid(True, linestyle="--", alpha=0.5)

# Leyenda
plt.legend()

# Ajustar márgenes automáticamente
plt.tight_layout()

# Mostrar gráfico
plt.show()

# =====

```

```
# Guardar modelo y normalizador
# =====

dump(modelo, "linear_regression.joblib")

dump(scaler, "scaler.joblib")

print("\nModelo guardado correctamente.")
print("StandardScaler guardado correctamente.")
```

5.1.2 Analisis_Statsmodels.py

```
# =====
# REGRESIÓN LINEAL MÚLTIPLE CON STATSMODELS
# =====

import pandas as pd
import numpy as np
import statsmodels.api as sm

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler

# =====
# Cargar datos
# =====

csv_data = "Datos/Datos_shank.xlsx"

df = pd.read_excel(
    csv_data
)

# =====
# Seleccionar variables
# =====

df = df[["Vida_Shank", "Presion_Percusion", "Presion_Rotacion",
"Presion_Avance", "Presion_Agua", "Presion_Aire", "RMR"]]

# Eliminar datos faltantes

df = df.dropna()

# =====
# Variables dependiente e independientes
# =====
```

```

y = df["Vida_Shank"]

X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",
"Presion_Agua", "Presion_Aire", "RMR"]]

# =====
# División entrenamiento / prueba
# =====

X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

X_test = scaler.transform(X_test)

# =====
# Agregar el intercepto
# =====

X_train = sm.add_constant(X_train)

# =====
# Entrenar modelo OLS
# =====

modelo = sm.OLS(y_train, X_train)

resultado = modelo.fit()

# =====
# Resumen completo
# =====

print("\n")
print("="*80)
print("RESUMEN DEL MODELO")
print("="*80)

```

```

print(resultado.summary())

# =====
# Parámetros del modelo
# =====

print("\n")
print("="*80)
print("COEFICIENTES")
print("="*80)

coeficientes = pd.DataFrame({

    "Coeficiente": resultado.params,
    "Error estándar": resultado.bse,
    "t": resultado.tvalues,
    "p-value": resultado.pvalues

})

print(coeficientes)

# =====
# R²
# =====

print("\n")
print("="*80)

print(f"R²                : {resultado.rsquared:.4f}")

print(f"R² Ajustado         : {resultado.rsquared_adj:.4f}")

print("="*80)

```

5.1.3 Predecir.py

```

# =====
# PREDICCIÓN CON DATOS NUEVOS
# =====

from joblib import load

# =====
# Cargar modelo y StandardScaler
# =====

```

```

modelo = load("linear_regression.joblib")

scaler = load("scaler.joblib")

# =====
# Nuevo dato
# =====

presion_percusion = 190.0

presion_rotacion = 45.0

presion_avance = 75.0

presion_agua = 8.0

presion_aire = 6.5

rmr = 55.0

nuevo = [[presion_percusion, presion_rotacion, presion_avance,
presion_agua, presion_aire, rmr]]

# =====
# Aplicar exactamente el mismo escalamiento
# utilizado durante el entrenamiento
# =====

nuevo_escalado = scaler.transform(nuevo)

# =====
# Predicción
# =====

vida_shank = modelo.predict(nuevo_escalado)

# =====
# Mostrar resultado
# =====

print()

print("=====")
print("PREDICCIÓN")
print("=====")

print(f"Presión Percusión : {presion_percusion}")
print(f"Presión Rotación : {presion_rotacion}")

```

```
print(f"Presión Avance      : {presion_avance}")
print(f"Presión Agua       : {presion_agua}")
print(f"Presión Aire        : {presion_aire}")
print(f"RMR                 : {rmr}")

print("-----")

print(f"Vida útil estimada : {vida_shank[0][0]:.2f}")

print("=====")
```

5.2 Anexo 3: Código par el Coupling

5.2.1 Entrenamiento.py

```
# =====  
# ENTRENAMIENTO DEL MODELO  
# =====  
  
import pandas as pd  
import matplotlib.pyplot as plt  
from sklearn.preprocessing import StandardScaler  
from sklearn.model_selection import train_test_split  
from sklearn.linear_model import LinearRegression  
from joblib import dump  
from sklearn.metrics import r2_score, mean_absolute_error,  
root_mean_squared_error  
  
# =====  
# Cargar datos  
# =====  
  
csv_data = "Datos/Datos_coupling.xlsx"  
  
df = pd.read_excel(csv_data)  
  
# Seleccionar columnas  
  
df = df[["Vida_Coupling", "Presion_Percusion", "Presion_Rotacion",  
"Presion_Avance", "Presion_Agua", "Presion_aire", "RMR"]]  
  
# Eliminar datos faltantes  
  
df = df.dropna()  
  
# =====  
# Variables independientes y dependiente  
# =====  
  
y = df[["Vida_Coupling"]]  
  
X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",  
"Presion_Agua", "Presion_aire", "RMR"]]  
  
# =====  
# Dividir datos  
# =====  
  
X_train, X_test, y_train, y_test = train_test_split(  
    X,
```

```

    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento de variables
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

# IMPORTANTE:
# El conjunto de prueba utiliza los parámetros
# calculados con el conjunto de entrenamiento.

X_test = scaler.transform(X_test)

# =====
# Entrenar modelo
# =====

modelo = LinearRegression()

modelo.fit(X_train, y_train)

# =====
# Resultados
# =====

print("\nIntercepto:")

print(modelo.intercept_)

print("\nCoeficientes:")

print(modelo.coef_)

# =====
# EVALUACIÓN DEL MODELO
# =====

# Predicciones sobre el conjunto de prueba
y_pred = modelo.predict(X_test)

# Calcular métricas
r2 = r2_score(y_test, y_pred)

```

```

mae = mean_absolute_error(y_test, y_pred)

rmse = root_mean_squared_error(y_test, y_pred)

# Mostrar resultados

print("\n=====")
print("EVALUACIÓN DEL MODELO")
print("=====")

print(f"R²      : {r2:.4f}")
print(f"MAE      : {mae:.4f}")
print(f"RMSE      : {rmse:.4f}")

print("=====\\n")

# =====
# GRÁFICO: VALORES REALES VS. VALORES PREDICHOS
# =====

plt.figure(figsize=(9, 7))

# Dibujar los puntos
plt.scatter(
    y_test,
    y_pred,
    s=15,
    alpha=0.30,
    label="Observaciones"
)

# Límites del gráfico
valor_min = min(y_test.min().values[0], y_pred.min())
valor_max = max(y_test.max().values[0], y_pred.max())

# Línea de predicción perfecta
plt.plot(
    [valor_min, valor_max],
    [valor_min, valor_max],
    color="red",
    linestyle="--",
    linewidth=2,
    label="Predicción perfecta (y = x)"
)

# Título
plt.title(
    "Valores reales vs. valores predichos (Coupling)",
    fontsize=15,

```

```

        fontweight="bold"
    )

# Etiquetas
plt.xlabel(
    "Vida útil real",
    fontsize=12
)

plt.ylabel(
    "Vida útil predicha",
    fontsize=12
)

# Cuadro con métricas
texto = (
    f"R²    = {r2:.4f}\n"
    f"MAE    = {mae:.4f}\n"
    f"RMSE   = {rmse:.4f}"
)

plt.text(
    0.03,
    0.97,
    texto,
    transform=plt.gca().transAxes,
    fontsize=11,
    verticalalignment="top",
    bbox=dict(
        facecolor="white",
        edgecolor="black",
        alpha=0.85
    )
)

# Cuadrícula
plt.grid(True, linestyle="--", alpha=0.5)

# Leyenda
plt.legend()

# Ajustar márgenes automáticamente
plt.tight_layout()

# Mostrar gráfico
plt.show()

# =====

```

```
# Guardar modelo y normalizador
# =====

dump(modelo, "linear_regression_coupling.joblib")

dump(scaler, "scaler_coupling.joblib")

print("\nModelo guardado correctamente.")
print("StandardScaler guardado correctamente.")
```

5.2.2 Analisis_Statsmodels.py

```
# =====
# REGRESIÓN LINEAL MÚLTIPLE CON STATSMODELS
# =====

import pandas as pd
import numpy as np
import statsmodels.api as sm

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler

# =====
# Cargar datos
# =====

csv_data = "Datos/Datos_coupling.xlsx"

df = pd.read_excel(
    csv_data
)

# =====
# Seleccionar variables
# =====

df = df[["Vida_Coupling", "Presion_Percusion", "Presion_Rotacion",
"Presion_Avance", "Presion_Agua", "Presion_aire", "RMR"]]

# Eliminar datos faltantes

df = df.dropna()

# =====
# Variables dependiente e independientes
```

```

# =====

y = df["Vida_Coupling"]

X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",
"Presion_Agua", "Presion_aire", "RMR"]]

# =====
# División entrenamiento / prueba
# =====

X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

X_test = scaler.transform(X_test)

# =====
# Agregar el intercepto
# =====

X_train = sm.add_constant(X_train)

# =====
# Entrenar modelo OLS
# =====

modelo = sm.OLS(y_train, X_train)

resultado = modelo.fit()

# =====
# Resumen completo
# =====

print("\n")
print("="*80)
print("RESUMEN DEL MODELO")

```

```

print("="*80)

print(resultado.summary())

# =====
# Parámetros del modelo
# =====

print("\n")
print("="*80)
print("COEFICIENTES")
print("="*80)

coeficientes = pd.DataFrame({

    "Coeficiente": resultado.params,
    "Error estándar": resultado.bse,
    "t": resultado.tvalues,
    "p-value": resultado.pvalues

})

print(coeficientes)

# =====
# R²
# =====

print("\n")
print("="*80)

print(f"R²                : {resultado.rsquared:.4f}")

print(f"R² Ajustado         : {resultado.rsquared_adj:.4f}")

print("="*80)

```

5.2.3 Predecir.py

```

# =====
# PREDICCIÓN CON DATOS NUEVOS
# =====

from joblib import load

# =====

```

```

# Cargar modelo y StandardScaler
# =====

modelo = load("linear_regression_coupling.joblib")

scaler = load("scaler_coupling.joblib")

# =====
# Nuevo dato
# =====

presion_percusion = 190.0

presion_rotacion = 45

presion_avance = 75.0

presion_agua = 10.0

presion_aire = 7.5

rmr = 60.0

nuevo = [[presion_percusion, presion_rotacion, presion_avance,
presion_agua, presion_aire, rmr]]

# =====
# Aplicar exactamente el mismo escalamiento
# utilizado durante el entrenamiento
# =====

nuevo_escalado = scaler.transform(nuevo)

# =====
# Predicción
# =====

vida_coupling = modelo.predict(nuevo_escalado)

# =====
# Mostrar resultado
# =====

print()

print("=====")
print("PREDICCIÓN")
print("=====")

```

```
print(f"Presión Percusión : {presion_percusion}")
print(f"Presión Rotación : {presion_rotacion}")
print(f"Presión Avance : {presion_avance}")
print(f"Presión Agua : {presion_agua}")
print(f"Presión Aire : {presion_aire}")
print(f"RMR : {rmr}")

print("-----")

print(f"Vida útil estimada : {vida_coupling[0][0]:.2f}")

print("=====")
```

5.3 Anexo 4: Código par la Barra

5.3.1 Entrenamiento.py

```
# =====  
# ENTRENAMIENTO DEL MODELO  
# =====  
  
import pandas as pd  
import matplotlib.pyplot as plt  
from sklearn.preprocessing import StandardScaler  
from sklearn.model_selection import train_test_split  
from sklearn.linear_model import LinearRegression  
from joblib import dump  
from sklearn.metrics import r2_score, mean_absolute_error,  
root_mean_squared_error  
  
# =====  
# Cargar datos  
# =====  
  
csv_data = "Datos/Datos_barra.xlsx"  
  
df = pd.read_excel(csv_data)  
  
# Seleccionar columnas  
  
df = df[["Vida_Barra", "Presion_Percusion", "Presion_Rotacion",  
"Presion_Avance", "Presion_Agua", "Presion_aire", "RMR"]]  
  
# Eliminar datos faltantes  
  
df = df.dropna()  
  
# =====  
# Variables independientes y dependiente  
# =====  
  
y = df[["Vida_Barra"]]  
  
X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",  
"Presion_Agua", "Presion_aire", "RMR"]]  
  
# =====  
# Dividir datos  
# =====  
  
X_train, X_test, y_train, y_test = train_test_split(  
    X,
```

```

    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento de variables
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

# IMPORTANTE:
# El conjunto de prueba utiliza los parámetros
# calculados con el conjunto de entrenamiento.

X_test = scaler.transform(X_test)

# =====
# Entrenar modelo
# =====

modelo = LinearRegression()

modelo.fit(X_train, y_train)

# =====
# Resultados
# =====

print("\nIntercepto:")

print(modelo.intercept_)

print("\nCoeficientes:")

print(modelo.coef_)

# =====
# EVALUACIÓN DEL MODELO
# =====

# Predicciones sobre el conjunto de prueba
y_pred = modelo.predict(X_test)

# Calcular métricas
r2 = r2_score(y_test, y_pred)

```

```

mae = mean_absolute_error(y_test, y_pred)

rmse = root_mean_squared_error(y_test, y_pred)

# Mostrar resultados

print("\n=====")
print("EVALUACIÓN DEL MODELO")
print("=====")

print(f"R²      : {r2:.4f}")
print(f"MAE      : {mae:.4f}")
print(f"RMSE      : {rmse:.4f}")

print("=====\\n")

# =====
# GRÁFICO: VALORES REALES VS. VALORES PREDICHOS
# =====

plt.figure(figsize=(9, 7))

# Dibujar los puntos
plt.scatter(
    y_test,
    y_pred,
    s=15,
    alpha=0.30,
    label="Observaciones"
)

# Límites del gráfico
valor_min = min(y_test.min().values[0], y_pred.min())
valor_max = max(y_test.max().values[0], y_pred.max())

# Línea de predicción perfecta
plt.plot(
    [valor_min, valor_max],
    [valor_min, valor_max],
    color="red",
    linestyle="--",
    linewidth=2,
    label="Predicción perfecta (y = x)"
)

# Título
plt.title(
    "Valores reales vs. valores predichos (Barra)",
    fontsize=15,

```

```

        fontweight="bold"
    )

# Etiquetas
plt.xlabel(
    "Vida útil real",
    fontsize=12
)

plt.ylabel(
    "Vida útil predicha",
    fontsize=12
)

# Cuadro con métricas
texto = (
    f"R²    = {r2:.4f}\n"
    f"MAE    = {mae:.4f}\n"
    f"RMSE   = {rmse:.4f}"
)

plt.text(
    0.03,
    0.97,
    texto,
    transform=plt.gca().transAxes,
    fontsize=11,
    verticalalignment="top",
    bbox=dict(
        facecolor="white",
        edgecolor="black",
        alpha=0.85
    )
)

# Cuadrícula
plt.grid(True, linestyle="--", alpha=0.5)

# Leyenda
plt.legend()

# Ajustar márgenes automáticamente
plt.tight_layout()

# Mostrar gráfico
plt.show()

# =====

```

```
# Guardar modelo y normalizador
# =====

dump(modelo, "linear_regression_barra.joblib")

dump(scaler, "scaler_barra.joblib")

print("\nModelo guardado correctamente.")
print("StandardScaler guardado correctamente.")
```

5.3.2 Analisis_Statsmodels.py

```
# =====
# REGRESIÓN LINEAL MÚLTIPLE CON STATSMODELS
# =====

import pandas as pd
import numpy as np
import statsmodels.api as sm

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler

# =====
# Cargar datos
# =====

csv_data = "Datos/Datos_barra.xlsx"

df = pd.read_excel(
    csv_data
)

# =====
# Seleccionar variables
# =====

df = df[["Vida_Barra", "Presion_Percusion", "Presion_Rotacion",
"Presion_Avance", "Presion_Agua", "Presion_aire", "RMR"]]

# Eliminar datos faltantes

df = df.dropna()

# =====
# Variables dependiente e independientes
```

```

# =====

y = df["Vida_Barra"]

X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",
"Presion_Agua", "Presion_aire", "RMR"]]

# =====
# División entrenamiento / prueba
# =====

X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

X_test = scaler.transform(X_test)

# =====
# Agregar el intercepto
# =====

X_train = sm.add_constant(X_train)

# =====
# Entrenar modelo OLS
# =====

modelo = sm.OLS(y_train, X_train)

resultado = modelo.fit()

# =====
# Resumen completo
# =====

print("\n")
print("="*80)
print("RESUMEN DEL MODELO")

```

```

print("="*80)

print(resultado.summary())

# =====
# Parámetros del modelo
# =====

print("\n")
print("="*80)
print("COEFICIENTES")
print("="*80)

coeficientes = pd.DataFrame({

    "Coeficiente": resultado.params,
    "Error estándar": resultado.bse,
    "t": resultado.tvalues,
    "p-value": resultado.pvalues

})

print(coeficientes)

# =====
# R²
# =====

print("\n")
print("="*80)

print(f"R²                : {resultado.rsquared:.4f}")

print(f"R² Ajustado         : {resultado.rsquared_adj:.4f}")

print("="*80)

```

5.3.3 Predecir.py

```

# =====
# PREDICCIÓN CON DATOS NUEVOS
# =====

from joblib import load

# =====

```

```

# Cargar modelo y StandardScaler
# =====

modelo = load("linear_regression_barra.joblib")

scaler = load("scaler_barra.joblib")

# =====
# Nuevo dato
# =====

presion_percusion = 185.0

presion_rotacion = 45.0

presion_avance = 75.0

presion_agua = 10.0

presion_aire = 7.5

rmr = 60.0

nuevo = [[
    presion_percusion,
    presion_rotacion,
    presion_avance,
    presion_agua,
    presion_aire,
    rmr
]]

# =====
# Aplicar exactamente el mismo escalamiento
# utilizado durante el entrenamiento
# =====

nuevo_escalado = scaler.transform(nuevo)

# =====
# Predicción
# =====

vida_barra = modelo.predict(nuevo_escalado)

# =====
# Mostrar resultado
# =====

```

```

print()

print("=====")
print("PREDICCIÓN")
print("=====")

print(f"Presión Percusión : {presion_percusion}")
print(f"Presión Rotación : {presion_rotacion}")
print(f"Presión Avance : {presion_avance}")
print(f"Presión Agua : {presion_agua}")
print(f"Presión Aire : {presion_aire}")
print(f"RMR : {rmr}")

print("-----")

print(f"Vida útil estimada : {vida_barra[0][0]:.2f}")

print("=====")

```

5.4 Anexo 5: Código par la Broca

5.4.1 Entrenamiento.py

```
# =====  
# ENTRENAMIENTO DEL MODELO  
# =====  
  
import pandas as pd  
import matplotlib.pyplot as plt  
from sklearn.preprocessing import StandardScaler  
from sklearn.model_selection import train_test_split  
from sklearn.linear_model import LinearRegression  
from joblib import dump  
from sklearn.metrics import r2_score, mean_absolute_error,  
root_mean_squared_error  
  
# =====  
# Cargar datos  
# =====  
  
csv_data = "Datos/Datos_broca.xlsx"  
  
df = pd.read_excel(csv_data)  
  
# Seleccionar columnas  
  
df = df[["Vida_Broca", "Presion_Percusion", "Presion_Rotacion",  
"Presion_Avance", "Presion_Agua", "Presion_Aire", "RMR"]]  
  
# Eliminar datos faltantes  
  
df = df.dropna()  
  
# =====  
# Variables independientes y dependiente  
# =====  
  
y = df[["Vida_Broca"]]  
  
X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",  
"Presion_Agua", "Presion_Aire", "RMR"]]  
  
# =====  
# Dividir datos  
# =====  
  
X_train, X_test, y_train, y_test = train_test_split(  
    X,
```

```

    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento de variables
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

# IMPORTANTE:
# El conjunto de prueba utiliza los parámetros
# calculados con el conjunto de entrenamiento.

X_test = scaler.transform(X_test)

# =====
# Entrenar modelo
# =====

modelo = LinearRegression()

modelo.fit(X_train, y_train)

# =====
# Resultados
# =====

print("\nIntercepto:")

print(modelo.intercept_)

print("\nCoeficientes:")

print(modelo.coef_)

# =====
# EVALUACIÓN DEL MODELO
# =====

# Predicciones sobre el conjunto de prueba
y_pred = modelo.predict(X_test)

# Calcular métricas
r2 = r2_score(y_test, y_pred)

```

```

mae = mean_absolute_error(y_test, y_pred)

rmse = root_mean_squared_error(y_test, y_pred)

# Mostrar resultados

print("\n=====")
print("EVALUACIÓN DEL MODELO")
print("=====")

print(f"R²      : {r2:.4f}")
print(f"MAE      : {mae:.4f}")
print(f"RMSE      : {rmse:.4f}")

print("=====\n")

# =====
# GRÁFICO: VALORES REALES VS. VALORES PREDICHOS
# =====

plt.figure(figsize=(9, 7))

# Dibujar los puntos
plt.scatter(
    y_test,
    y_pred,
    s=15,
    alpha=0.30,
    label="Observaciones"
)

# Límites del gráfico
valor_min = min(y_test.min().values[0], y_pred.min())
valor_max = max(y_test.max().values[0], y_pred.max())

# Línea de predicción perfecta
plt.plot(
    [valor_min, valor_max],
    [valor_min, valor_max],
    color="red",
    linestyle="--",
    linewidth=2,
    label="Predicción perfecta (y = x)"
)

# Título
plt.title(
    "Valores reales vs. valores predichos (Broca)",
    fontsize=15,

```

```

        fontweight="bold"
    )

# Etiquetas
plt.xlabel(
    "Vida útil real",
    fontsize=12
)

plt.ylabel(
    "Vida útil predicha",
    fontsize=12
)

# Cuadro con métricas
texto = (
    f"R²    = {r2:.4f}\n"
    f"MAE    = {mae:.4f}\n"
    f"RMSE    = {rmse:.4f}"
)

plt.text(
    0.03,
    0.97,
    texto,
    transform=plt.gca().transAxes,
    fontsize=11,
    verticalalignment="top",
    bbox=dict(
        facecolor="white",
        edgecolor="black",
        alpha=0.85
    )
)

# Cuadrícula
plt.grid(True, linestyle="--", alpha=0.5)

# Leyenda
plt.legend()

# Ajustar márgenes automáticamente
plt.tight_layout()

# Mostrar gráfico
plt.show()

# =====

```

```
# Guardar modelo y normalizador
# =====

dump(modelo, "linear_regression_broca.joblib")

dump(scaler, "scaler_broca.joblib")

print("\nModelo guardado correctamente.")
print("StandardScaler guardado correctamente.")
```

5.4.2 Analisis_Statsmodels.py

```
# =====
# REGRESIÓN LINEAL MÚLTIPLE CON STATSMODELS
# =====

import pandas as pd
import numpy as np
import statsmodels.api as sm

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler

# =====
# Cargar datos
# =====

csv_data = "Datos/Datos_broca.xlsx"

df = pd.read_excel(
    csv_data
)

# =====
# Seleccionar variables
# =====

df = df[["Vida_Broca", "Presion_Percusion", "Presion_Rotacion",
"Presion_Avance", "Presion_Agua", "Presion_Aire", "RMR"]]

# Eliminar datos faltantes

df = df.dropna()

# =====
# Variables dependiente e independientes
```

```

# =====

y = df["Vida_Broca"]

X = df[["Presion_Percusion", "Presion_Rotacion", "Presion_Avance",
"Presion_Agua", "Presion_Aire", "RMR"]]

# =====
# División entrenamiento / prueba
# =====

X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.20,
    random_state=42
)

# =====
# Escalamiento
# =====

scaler = StandardScaler()

X_train = scaler.fit_transform(X_train)

X_test = scaler.transform(X_test)

# =====
# Agregar el intercepto
# =====

X_train = sm.add_constant(X_train)

# =====
# Entrenar modelo OLS
# =====

modelo = sm.OLS(y_train, X_train)

resultado = modelo.fit()

# =====
# Resumen completo
# =====

print("\n")
print("="*80)
print("RESUMEN DEL MODELO")

```

```

print("="*80)

print(resultado.summary())

# =====
# Parámetros del modelo
# =====

print("\n")
print("="*80)
print("COEFICIENTES")
print("="*80)

coeficientes = pd.DataFrame({

    "Coeficiente": resultado.params,
    "Error estándar": resultado.bse,
    "t": resultado.tvalues,
    "p-value": resultado.pvalues

})

print(coeficientes)

# =====
# R²
# =====

print("\n")
print("="*80)

print(f"R²                : {resultado.rsquared:.4f}")

print(f"R² Ajustado         : {resultado.rsquared_adj:.4f}")

print("="*80)

```

5.4.3 Predecir.py

```

# =====
# PREDICCIÓN CON DATOS NUEVOS
# =====

from joblib import load

# =====

```

```

# Cargar modelo y StandardScaler
# =====

modelo = load("linear_regression_broca.joblib")

scaler = load("scaler_broca.joblib")

# =====
# Nuevo dato
# =====

presion_percusion = 185.0

presion_rotacion = 45.0

presion_avance = 75.0

presion_agua = 10.0

presion_aire = 7.5

rmr = 60.0

nuevo = [[
    presion_percusion,
    presion_rotacion,
    presion_avance,
    presion_agua,
    presion_aire,
    rmr
]]

# =====
# Aplicar exactamente el mismo escalamiento
# utilizado durante el entrenamiento
# =====

nuevo_escalado = scaler.transform(nuevo)

# =====
# Predicción
# =====

vida_broca = modelo.predict(nuevo_escalado)

# =====
# Mostrar resultado
# =====

```

```

print()

print("=====")
print("PREDICCIÓN")
print("=====")

print(f"Presión Percusión : {presion_percusion}")
print(f"Presión Rotación : {presion_rotacion}")
print(f"Presión Avance : {presion_avance}")
print(f"Presión Agua : {presion_agua}")
print(f"Presión Aire : {presion_aire}")
print(f"RMR : {rmr}")

print("-----")

print(f"Vida útil estimada : {vida_broca[0][0]:.2f}")

print("=====")

```

5.5 Anexo 6: Galería de fotografías

Figura 38

Boca mina RP 300 Mina San Cristóbal



Figura 39

Fotografía de mi persona después de la charla seguridad



Figura 40

Afilado de brocas



Figura 41

Charla de capacitación al personal



Figura 42

Transporte del acero de perforación a interior mina



Figura 43

Control de identidad en el tablero de control



Figura 44
Base de datos

Base de datos

178

ID	Vida_Shank	Presion_Percusion	Presion_Rotacion	Presion_Avance	Presion_Agua	Presion_Aire	RMR	Diametro_Broca
1	4449.47	187.7	34.9	89.7	10	4.8	55.8	45
2	5004.82	187.2	35.3	92.7	11.4	5.1	53.8	45
3	4357.42	189.5	44.5	88.7	8.9	5.1	48	45
4	3931.92	189.9	42.6	98.3	10.3	4.4	44.5	45
5	6058.51	187.9	27.9	83.6	12	8.9	54.9	45
6	5688.79	185.5	39.8	76.8	4.4	6.5	50.1	45
7	1013.76	200	38.3	91.8	6.1	7.7	56.6	45
8	4741.47	196.2	29.9	77.4	12.2	4.4	52.4	45
9	5630.27	183.3	49	73.1	5.4	5.7	50.8	45
10	4272.69	188.7	38.1	88.6	6.1	8.2	54.4	45
11	2860.85	200	44.2	85	9.9	4.7	48.8	45
12	6117.64	184.2	37.7	74	7.8	5.3	49.2	45
13	6271.56	180	41.8	85.9	7.7	8.7	50.6	45
14	7627.62	184.2	25	88.7	6.3	6.1	45.2	45
15	12949.12	180	25	65	14	9.4	38	45
16	5935.37	193.8	46.6	68.4	5.6	7	40.1	45
17	4422.04	187.1	44.3	94.8	11.2	5.4	46.2	45
18	9165.95	188.1	26.7	66.6	11.1	9.3	49.6	45
19	2649.63	190.2	42	87.1	6.6	5.7	52.9	45
20	2424.99	190.2	38.2	97.7	10.4	6.9	60	45
21	1260.04	191.4	40	94.7	5.7	7.6	59.7	45
22	3401.26	187.1	47.3	76.7	7.4	4.8	53.6	45
23	2836.47	193.8	40.7	89.3	8.9	6.1	49	45
24	2443.28	193.9	39.5	96.9	4.5	4.5	43.3	45
25	1295.7	189.2	49.2	99.3	4.6	5.6	53.4	45
26	3332.38	185.3	36.8	88.8	5.8	5.1	56.3	45
27	5443.73	188.9	40.3	76.4	8	9.2	51.3	45
28	2223.82	199.7	34.1	89	8.6	7	54.3	45
29	2943.45	184	51.6	97	9	7.9	55.8	45
30	4612.84	187	53.8	75.6	9	6.3	50.3	45
31	3529.28	193.2	35.3	91.2	10.4	4.3	50.9	45
32	3625.6	193.5	52.6	77.5	10.9	8.8	55.2	45
33	4893.56	183.6	31.7	86.5	6	5.8	55.3	45
34	5942.99	191.8	31.6	89.7	11.5	7.8	47.1	45
35	6272.48	187	39.6	74.4	12.4	4	49.1	45
36	3737.15	194.1	33.8	100	9.6	6.9	49.1	45
37	1557.22	197.8	45.6	76.9	3.1	5	50.2	45
38	2250.64	194.4	43	92.3	6.6	5.6	52.2	45
39	1105.51	190	46.4	92.1	4.4	7.9	60	45
40	2176.58	193.5	45.4	93.5	9.4	8.5	55.2	45
41	1157.02	192.9	47.1	98	6.2	8.9	57.7	45
42	6052.72	184	39.2	82.8	7	6.2	50.5	45
43	1130.5	200	45.5	83.4	9.3	7	59.3	45
44	3924	189.9	53.9	74.6	6.8	4.4	46.8	45
45	2168.04	189.4	33.7	96.2	5.2	5.7	57.9	45
46	3565.86	200	37.4	82.2	7.7	6.5	49	45
47	1998.27	197.9	45.1	77.4	7.7	6.9	56.1	45
48	3975.51	195.3	29.1	92.5	5.4	6.4	43.2	45
49	4424.48	186.4	32.8	96.3	7.1	8.8	53.3	45
50	2638.96	191.4	46.2	81.6	7.4	4.5	56.5	45
51	2135.73	189.2	51.8	92.9	8.6	5.2	54.3	45
52	4319.02	188.8	27.2	92.4	5.8	6.5	51.6	45
53	2507.28	194.1	55	77.4	5.9	5.1	49.4	45
54	3700.88	192.6	46.2	79.9	12.2	5.4	49.3	45
55	5480.91	182.6	46.6	78.6	8.1	4.9	51.6	45
56	5177.94	199.7	35.5	71.2	6.4	5.3	42.5	45
57	12836.65	180	27.4	65	8.5	10	38	45
58	3237.89	195.8	51.8	79.7	4.9	6.8	47.2	45
59	1818.74	200	46.7	86.5	10.8	8.3	54.4	45
60	3208.63	197.3	50.2	78	9.9	4.5	50.6	45
61	1818.74	192.2	37.4	94.8	6.1	8.6	60	45
62	3010.51	193.6	48.3	75.6	8.4	5	54	45
63	705.31	200	43.4	87.1	9.3	7.2	57.2	45
64	2067.76	199.4	41.6	93.4	6.2	8.2	46.4	45
65	2167.43	193.3	41.4	94.1	9.9	7.9	55.3	45
66	630.02	196.8	40.2	77.9	4.6	4.4	57.1	45
67	1759.31	196.9	39.1	93.7	8.4	5.1	50.4	45
68	2462.48	191.9	55	88.2	11.5	6.4	55.8	45
69	2187.24	193	53.1	74.3	7.4	3.7	48.9	45
70	1909.88	195.8	55	92.9	7.3	7.7	46.6	45
71	1089.66	194.4	55	79.9	4.7	7	52.1	45
72	1252.12	199.1	55	89.9	9.9	7.2	52.4	45
73	5281.88	194.9	42.3	71.2	7.7	8	49.8	45

ID	Vida_Barra	Presion_Percusion	Presion_Rotacion	Presion_Avance	Presion_Agua	Presion_aire	RMR	Diametro_Broca
1	1894.64	180	34.9	95	12	7.5	58	45
2	3880.71	178	35.3	94	11	7	56	45
3	2553.00	184	44.5	96	12	7.8	60	45
4	6334.66	181	42.6	68	13	9.5	70	45
5	5445.25	182	27.9	72	12	8.8	68	45
6	1222.25	198	39.8	92	5	4.5	38	45
7	1638.60	195	38.3	88	6	5	42	45
8	1386.23	197	29.9	90	5	4.8	40	45
9	2135.73	192	49	85	8	6.2	48	45
10	3673.14	187	38.1	78	10	7.5	58	45
11	4614.06	185	44.2	74	11	8.1	62	45
12	4483.30	185	37.7	75	11	8	61	45
13	2583.48	190	41.8	83	9	6.8	52	45
14	2873.35	189	25	82	9	7	54	45
15	4539.69	185	25	75	11	8.1	62	45
16	3284.83	188	46.6	80	10	7.3	56	45
17	3534.46	187	44.3	79	10	7.4	57	45
18	2294.23	191	26.7	84	8	6.5	50	45
19	2504.24	190	42	83	9	6.7	51	45
20	3466.49	188	38.2	79	10	7.4	56	45
21	1157.02	199	40	93	4	4.2	36	45
22	2001.01	193	47.3	86	7	6	47	45
23	2924.25	189	40.7	81	9	7.1	54	45
24	1977.85	193	39.5	87	7	5.9	46	45
25	5078.58	183	49.2	72	12	8.6	66	45
26	1894.03	194	36.8	88	7	5.8	45	45
28	2453.03	191	40.3	84	8	6.6	51	45
29	3152.85	188	34.1	80	9	7.2	55	45
30	2503.63	190	51.6	83	9	6.7	51	45
31	4201.36	186	53.8	76	11	7.8	60	45
32	4798.16	184	35.3	73	12	8.3	64	45
33	2947.11	189	52.6	81	9	7.1	54	45
34	2699.61	190	31.7	82	9	6.9	53	45
35	1145.13	199	31.6	93	4	4.2	36	45
37	4695.44	184	39.6	74	11	8.2	63	45
39	2305.20	191	33.8	84	8	6.5	50	45
40	1620.62	195	45.6	89	6	5.1	42	45
42	1874.82	194	43	88	6	5.7	45	45
43	3851.76	187	46.4	77	10	7.6	59	45
44	2309.77	191	45.4	84	8	6.5	50	45
45	4944.47	183	47.1	73	12	8.4	65	45
46	2051.91	192	39.2	86	7	6.1	47	45
47	4589.07	185	45.5	75	11	8.1	62	45
48	3715.82	187	53.9	78	10	7.5	58	45
49	3712.16	187	33.7	78	10	7.5	58	45
51	1632.51	195	37.4	88	6	5.1	42	45
52	3219.30	188	45.1	80	10	7.3	56	45
53	2603.30	190	29.1	82	9	6.8	52	45
54	1842.52	194	32.8	88	6	5.6	44	45
56	4449.47	185	46.2	75	11	8	61	45
57	2948.03	189	51.8	81	9	7.1	54	45
59	3404.01	188	27.2	79	10	7.4	56	45
60	1734.01	194	55	89	6	5.4	43	45
61	3718.86	187	46.2	78	10	7.5	58	45
63	2365.25	191	46.6	84	8	6.6	50	45
64	2385.97	191	35.5	84	8	6.6	50	45
65	6512.66	180	27.4	66	13	9.8	71	45
67	1128.67	199	51.8	93	4	4.2	36	45
68	3937.10	186	46.7	77	11	7.7	59	45
69	1991.56	193	50.2	86	7	6	46	45
70	4328.16	185	37.4	76	11	7.9	61	45
71	2532.58	190	48.3	83	9	6.7	51	45
72	1604.77	195	43.4	89	6	5	41	45
73	2860.85	189	41.6	82	9	7	54	45
74	4100.47	186	41.4	77	11	7.8	60	45
75	1157.02	199	40.2	93	4	4.2	36	45
77	1006.75	200	39.1	94	4	4.1	35	45
80	2635.91	190	55	82	9	6.8	52	45
81	1331.37	198	53.1	91	5	4.6	39	45
82	5229.45	182	55	71	12	8.7	67	45
83	5942.99	181	55	69	13	9.2	69	45
84	5245.30	182	55	71	12	8.7	67	45
85	3101.04	188	42.3	80	9	7.2	55	45
86	2834.34	189	46.2	82	9	7	53	45
87	1930.30	193	46.6	87	7	5.8	45	45
88	4921.30	183	35.5	73	12	8.4	65	45

Figura 45

Reporte de operaciones de equipo

VOLCAN

Reporte de Operación de Equipos: JUMBO-SIMBA

Nº 2111-104 017494

Macro:

Mina	g/c	Empresa Prov. Acaros
Fecha	27-02-25	Long. Barra (pies)
Guardia	D.P.	Diám. Broca Perf. (mm)
Empresa	Volcan	Diám. Broca Rim. (mm)
Equipo	J.160	

Horómetros		Inicial	Final
Diésel		2068.9	2069.2
Eléctrico 1		3610.7	3612.5
Eléctrico 2			
Percusión 1		947.7	948.7
Percusión 2			
Compresor 1			
Compresor 2			

No	Hora Inicio	Hora Final	Cod. Activ.	Veta	Zona	Nivel	Labor	Labor Ref.	Mat. M/D	# Barras	Brazo 1			Brazo 2			Dimen. Labor	Ancho/ Alto/ Espac.	Observaciones
											Long. Perf.	# Tal. Perf.	# Tal. Rim.	Long. Perf.	# Tal. Perf.	# Tal. Rim.			
1	7:00	8:30	200		II	1220	SN-65-00												
2	8:50	9:00	202		II	1220	SN-65-00												
3	9:00	3:20	307		II	1220	SN-65-00												
4	3:20	3:30	305		II	1220	SN-65-00												
5	3:30	5:10	103		II	1220	SN-65-00												
6																			
7																			
8																			
9																			
10																			
11																			
12																			
13																			
14																			
15																			
16																			
17																			
18																			
19																			
20																			
21																			

OBSERVACIONES:

411

V. Cardona Meza

Nombre Operador

Datos Operador

Motivo

Falla

Mant.P

Nombre Sobrestante

Jefe Guardia ECM

Jefe Guardia Volcan

Jefe Técnico Mantenimiento

Residente ECM

Observaciones

Galaxy A55 5G
28 de febrero de 2025 14:44

Figura 46
Diagrama de Flujo




Figura 47

Parámetros de perforación, parámetros geomecánicos la vida útil de aceros de perforación

PARAMETROS OPERATIVOS	BAJA	ALTA
Presión Percusión	130-140	180-200
Presión Rotación	25-55	
Presión Avance	40	65-100
Presión agua	3--14	
Presión aire	3.5-10	
VIDA UTIL DE ACEROS DE PERFORACION		
Shank	4000 m	
Coupling	5000 m	
Barra	3500 m	
Broca	280 m	

**UNSCH****FACULTAD DE
INGENIERÍA**
DE MINAS, GEOLOGÍA Y CIVIL**ACTA DE SUSTENTACIÓN DE TESIS N° 71-2026-FIMGC****PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO DE MINAS**

En la Universidad Nacional de San Cristóbal de Huamanga, en la ciudad de Ayacucho, en cumplimiento a la **Resolución Decanal No 422-2026-FIMGC-D**, a los veinticuatro días del mes de **septiembre de 2026**, siendo las **4:12 p.m.**, reunidos en el **Auditorio de la Escuela Profesional de Ingeniería de Minas**, bajo la presidencia del **MSc. Ing. José Ernesto ESTRADA CÁRDENAS**, y los miembros: **Mtro. Fortunato DE LA CRUZ PALOMINO**, **Mg. Ing. Edmundo CAMPOS ARZAPALO** y **MSc. Ing. Carlos Alberto QUISPE HUAROTO**, actuando como secretario docente el **Ing. Saul Walter RETAMOZO FERNÁNDEZ**, para proceder a la sustentación de tesis para optar el **Título Profesional de Ingeniero de Minas**, del Bachiller en Ciencias de la Ingeniería de Minas:

YEMERSON MAUCAYLLE LAUPA


Quien presentó la tesis denominada:

Predicción de la vida útil de la columna de perforación basado en parámetros operativos mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026


Los señores miembros del jurado luego de expuesta la tesis y absueltas las preguntas, deliberaron y declararon:


Aprobado con 17 (diecisiete)

Siendo las **5:25 p.m.** del día **24 de septiembre del 2026**, culmina el acto de sustentación de tesis, y en conformidad de lo actuado los miembros del jurado firmamos al pie del presente.


MSc. Ing. José Ernesto ESTRADA CÁRDENAS
Presidente


Mg. Ing. Edmundo CAMPOS ARZAPALO
Miembro


MSc. Ing. Carlos Alberto QUISPE HUAROTO
Miembro


Mtro. Fortunato DE LA CRUZ PALOMINO
Miembro - Asesor


Ing. Saul Walter RETAMOZO FERNÁNDEZ
Secretario docente de la FIMGC

FACULTAD DE INGENIERÍA
DE MINAS Y CIVIL
Av. Independencia S/N
Ciudad Universitaria
Central Tel. 066 312510
Anexo 151



UNSCH

CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

El que suscribe; en mi calidad de Instructor de Originalidad de Trabajos de Investigación y encargado de certificar la originalidad de la tesis abajo indicado y por lo tanto responsable verificador de originalidad de trabajo de tesis de pregrado en primera instancia, en cumplimiento a la Resolución de Consejo Universitario N°039-2021-UNSCH-CU, Reglamento de Originalidad de Trabajos de Investigación UNSCH, deja constancia que:

- Apellidos y Nombres del Bach. : MAUCAYLLE LAUPA, Yemerson
- Escuela Profesional : Ingeniería de Minas
- Título de la Tesis : Predicción de la vida útil de la columna de perforación basado en parámetros operativos mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026
- Evaluación de la originalidad : 15% de similitud

Por tanto, según los artículos 12, 13 y 17 del Reglamento de Originalidad de Trabajos de Investigación, **es procedente la constancia de originalidad** para los fines que crea conveniente.

Ayacucho, 06 de octubre de 2026

MBA Ing° Leonil Fernando Quispe Aronés
Instructor de Originalidad de Trabajos de Investigación

Predicción de la vida útil de la columna de perforación basado en parámetros operativos mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026

por Yemerson MAUCAYLLE LAUPA

Fecha de entrega: 06-oct-2026 09:53p. m. (UTC-0500)

Identificador de la entrega: 3052775664

Nombre del archivo: Tesis_Yemerson_MAUCAYLLE_LAUPA_.pdf (3.37M)

Total de palabras: 41592

Total de caracteres: 245863

Predicción de la vida útil de la columna de perforación basado en parámetros operativos mediante regresión lineal múltiple en la Unidad Minera San Cristóbal, 2026

INFORME DE ORIGINALIDAD

15%	15%	6%	9%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.unsch.edu.pe	2%
	Fuente de Internet	
2	Submitted to Universidad Nacional de San Cristóbal de Huamanga	2%
	Trabajo del estudiante	
3	hdl.handle.net	1%
	Fuente de Internet	
4	Submitted to Universidad TecMilenio	1%
	Trabajo del estudiante	
5	Submitted to Universidad Anahuac México Sur	1%
	Trabajo del estudiante	
6	apirepositorio.unh.edu.pe	1%
	Fuente de Internet	
7	dokumen.pub	<1%
	Fuente de Internet	
8	Joaquín Moncho Vasallo. "Análisis de regresión lineal simple y múltiple", Elsevier BV, 2015	<1%
	Publicación	
9	Submitted to RDI Distance Learning	<1%
	Trabajo del estudiante	
10	repositorio.unprg.edu.pe	<1%
	Fuente de Internet	
11	repositorio.undac.edu.pe	<1%
	Fuente de Internet	
12	Submitted to Centro Europeo de Postgrado - CEUPE	<1%
	Trabajo del estudiante	
13	Apolinario Villafan, Ever Panchito Chuquillanqui Herrera, Luis Ricardo Loayza Susanibar, Guido Francisco Mancha Mulato et al. "Modelo ProLab: NEURALVISIO minero plataforma de asistencia remota en seguridad y eficiencia con integración	<1%

de realidad aumentada y redes neuronales", Pontificia Universidad Catolica del Peru (Peru), 2025

Publicación

14	Submitted to Universidad Continental	Trabajo del estudiante	<1 %
15	zaguan.unizar.es	Fuente de Internet	<1 %
16	juandomingofarnos.wordpress.com	Fuente de Internet	<1 %
17	Submitted to Tanglin Trust School	Trabajo del estudiante	<1 %
18	cienciayeducacion.com	Fuente de Internet	<1 %
19	Submitted to Universitat Oberta de Catalunya	Trabajo del estudiante	<1 %
20	Submitted to Universidad Andrés Bello	Trabajo del estudiante	<1 %
21	cathi.uacj.mx	Fuente de Internet	<1 %
22	repositorio.utn.edu.ec	Fuente de Internet	<1 %
23	repositorio.unap.edu.pe	Fuente de Internet	<1 %
24	Submitted to Universidad de Manizales	Trabajo del estudiante	<1 %
25	qdoc.tips	Fuente de Internet	<1 %
26	Loja Yoplac, Jonathan Pareja Alcazaba, Veronica Cristina Suarez Rivera, Patsy Katheryne Rubio Quevedo, Frankie Walter. "Calidad en el servicio al cliente en el sector educacion de carreras universitarias de pregrado de la universidad ESAN.", Pontificia Universidad Catolica del Peru - CENTRUM Catolica (Peru), 2021	Publicación	<1 %
27	www.feciv.ufu.br	Fuente de Internet	<1 %
28	Submitted to Escuela Politecnica Nacional	Trabajo del estudiante	<1 %

29	Xavier Vasques. "Machine Learning Theory and Applications", Wiley, 2024 Publicación	<1 %
30	elblogdelprogramador.com Fuente de Internet	<1 %
31	Gamboa Gonzáles, Willy Alexander. "Estimación del Consumo de Combustible de Ómnibus Interprovinciales por el Método de Análisis de Regresión Lineal Múltiple Basado en Parámetros Operacionales y Estilos de Conducción en la Ruta Lima-Trujillo", Pontificia Universidad Catolica del Peru (Peru), 2023 Publicación	<1 %
32	repositorio.upeu.edu.pe Fuente de Internet	<1 %
33	ebin.pub Fuente de Internet	<1 %
34	Submitted to UNIBA Trabajo del estudiante	<1 %
35	es.wikipedia.org Fuente de Internet	<1 %
36	repositorio.uancv.edu.pe Fuente de Internet	<1 %
37	certidevs.com Fuente de Internet	<1 %
38	Submitted to Universidad Nacional de Ingenieria Trabajo del estudiante	<1 %
39	repositorioacademico.upc.edu.pe Fuente de Internet	<1 %
40	Submitted to Universidad Europea de Madrid Trabajo del estudiante	<1 %
41	Canaza Ortiz, Miler Showil. "Análisis multitemporal de la cobertura glaciar del nevado Ananea (Puno, Perú) y su influencia climática, período 1985 – 2022", Universidad Nacional del Altiplano de Puno (Peru) Publicación	<1 %
42	repositorio.esge.edu.pe Fuente de Internet	<1 %
43	partidodeltrabajo.com.mx Fuente de Internet	<1 %

44	Fuente de Internet	<1 %
45	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1 %
46	www.slideshare.net Fuente de Internet	<1 %
47	www.stuvia.com Fuente de Internet	<1 %
48	fr.scribd.com Fuente de Internet	<1 %
49	repositorio.continental.edu.pe Fuente de Internet	<1 %
50	Submitted to Trabajo del estudiante	<1 %
51	repositorio.unsaac.edu.pe Fuente de Internet	<1 %
52	repositorio.puce.edu.ec Fuente de Internet	<1 %

Excluir citas
Excluir bibliografía

Activo
Activo

Excluir coincidencias

< 30 words