

UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA METALURGICA

Profesor Patrocinante
Sr. Jorge Cubillos Miranda

**ESTIMACIÓN DE LA FRAGMENTACIÓN PRODUCTO DE LA TRONADURA DE
ROCAS EN MINERÍA A CIELO ABIERTO UTILIZANDO MODELOS
PREDICTIVOS Y ALGORITMOS DE REGRESIÓN**



FERNANDA JOSÉ ROJAS VALENZUELA

Informe de Memoria de Título
para optar al Título de
Ingeniera Civil de Minas

MARZO 2021

AGRADECIMIENTOS

En primer lugar, agradezco a mi familia, que siempre ha sido un pilar fundamental y la luz que ilumina el camino que deseo seguir para esta aventura llamada vida. En primer lugar, mis padres, Alberto y Miriam, por darme la vida, educación, valores, amor y apoyo incondicional en todos esos días grises donde pensé que no lo lograría. A mi hermanita Maite por sentarse junto a mí todo este proceso y escucharme por horas hablando sobre la memoria, leer mis informes y acompañarme durante todos estos días de trabajo y reuniones a pesar de tener solo 12 añitos.

En segundo lugar, a mi profesor Jorge Cubillos, por guiarme en este proceso, apoyarme y soportarme en cada reunión. A pesar de sus obligaciones laborales y personales, nunca dejó de mostrar su dedicación y entrega por la formación de profesionales de excelencia. Probablemente usted guío y continuará guiando, el camino de muchos estudiantes, sin embargo, para esta futura profesional, solo habrá un profesor guía que hizo que este logro personal se concretara.

En tercer lugar, es imperativo extender mi más profundo agradecimiento al Sr. Diego Quezada, Superintendente de Perforación y Tronadura en Minera Los Pelambres, quien confió en nuestro trabajo y gentilmente nos proporcionó una base de datos para poder aplicar y concretar las estimaciones de fragmentación.

Finalmente, no puedo dejar pasar esta oportunidad sin agradecer a mi corazón, Ariel, por su constante apoyo y contención en los días difíciles, por su compañía durante varios de los años de esta etapa universitaria, por su guía en aspectos técnicos del presente trabajo y por ser una parte fundamental en mi vida. A mis queridos amigos y futuros colegas, Matias y Guillermo, por ayudarme siempre y soportarme durante casi toda mi formación universitaria, los quiero muchísimo. A mis queridas amigas de siempre, por estar presentes desde mi enseñanza básica y ser parte constante de mi vida, gracias por todos los cafecitos, queques, almuerzos terapéuticos y juntas en medio de la tempestad. Extiendo mi más profundo agradecimiento a todos quienes han aportado a mi formación y a la culminación de este proyecto a través de acciones o palabras de apoyo, gracias.

RESUMEN

El presente trabajo surge de la necesidad de proponer como mejorar la estimación de fragmentación producto de la tronadura en minería a cielo abierto, para lo cual se desarrolló una investigación aplicada con la finalidad de entender cómo es que se produce la estimación de fragmentación desde un punto de vista teórico, y también, exponer cómo es que ésta se integra dentro de un proceso industrial. Para esto se realizó una exhaustiva investigación de los modelos empíricos utilizados y se indagó en el contexto industrial en el que estos son aplicados.

En este contexto surge la idea de la aplicación de algoritmos de máquinas de aprendizaje, conocidos como algoritmos de *Machine Learning* (ML) para la estimación de fragmentación, basándose en una serie de estudios realizados con otras herramientas de la inteligencia artificial aplicadas a la estimación de fragmentación. De este modo se determinó que el objetivo general fuese indagar si la estimación de fragmentación, específicamente el P50, podría ser eventualmente mejorada mediante la incorporación de algoritmos de *Machine Learning*.

Tras perseverar en la búsqueda de recursos y enfrentar una serie de limitaciones, fue posible acceder a una base de datos provenientes de Minera Los Pelambres con información de diseño, explosivo y granulometría. Esta permitió realizar la estimación de fragmentación utilizando los modelos Kuz-Ram y Kuznetsov-Cunningham-Ouchternoly (KCO), donde se obtuvo un R^2 nulo para ambos modelos y altos valores del error cuadrático medio. Posteriormente se entrenaron varios modelos utilizando la aplicación *Regression Learner* de MATLAB combinando diferentes predictores, donde se obtuvieron una serie de modelos predictivos entre los cuales, el mejor resultado de estimación fue uno basado en arboles de decisión, el que tuvo una bondad de ajuste del 0.73 y un RMSE de 16.21 utilizando una base de datos sin normalizar. Adicionalmente se estudió el impacto que tiene en la estimación la normalización de la base de datos, debido a la variedad en los órdenes de magnitud de las variables involucradas.

Finalmente, en base a los resultados obtenidos, se pudo concluir que existe un gran potencial en la incorporación de algoritmos de regresión para la estimación de la fragmentación, ya que estos presentan una serie de ventajas relacionadas a la cantidad mínima de información requerida para su aplicación y a un mejor desempeño en comparación con los modelos semiempíricos.

SUMMARY

The present work arises from the need to improve the estimation of fragmentation product of blasting in open pit mining, for which an applied research was developed to understand how the fragmentation estimation is produced from a point of theoretical view, and also, expose how it is integrated into an industrial process. For this, an exhaustive investigation of the common empirical models for this type of estimation was carried out to list most of the industrial context in which they are applied.

In this context, the idea of applying machine learning (ML) algorithms, arises in the estimation of fragmentation based on a series of studies carried out with other artificial intelligence tools applied to the estimation of fragmentation. In this approach, it was determined that the general task was to investigate whether the fragmentation estimate, specifically the P50, could eventually be improved by incorporating Machine Learning algorithms.

After persevering in the search for resources and facing a series of limitations, it was possible to access a database from Los Pelambres copper mine including design, explosives and granulometry. Using this database, it was possible to estimate the fragmentation estimation using the Kuz-Ram and Kuznetsov-Cunningham-Ouchternoly (KCO) models, where a null R^2 was obtained for both models and high values of the mean square error. Subsequently, several models were trained using the MATLAB Regression Learner application combining different predictors, where a series of predictive models were obtained where the best estimation result was the one based on decision trees, which had a goodness of fit of 0.73 and an RMSE of 16.21 within an unnormalized database. In addition, the impact of the database normalization on the estimation was studied.

Finally, based on the obtained results, it was concluded that there is a great potential in the incorporation of regression algorithms to estimate the fragmentation of blasted rock, since these algorithms present a series of advantages in terms of the minimum amount of information required for their application. Moreover, the result showed better performance compared to semi-empirical models.

ÍNDICE DE CONTENIDOS

AGRADECIMIENTOS.....	I
RESUMEN	II
SUMMARY	III
ÍNDICE DE CONTENIDOS.....	IV
ÍNDICE DE TABLAS	VI
ÍNDICE DE FIGURAS.....	VII
NOMENCLATURA VIII	
1	INTRODUCCIÓN
1.1	CONTEXTO GENERAL Y ESTADO DEL ARTE
1.2	PROPÓSITO FUNDAMENTAL Y NATURALEZA DE LA INVESTIGACIÓN
1.3	HIPÓTESIS DE TRABAJO.....
1.4	OBJETIVOS
1.5	ALCANCES Y LIMITACIONES.....
1.6	METODOLOGÍA.....
2	CONTEXTO TEÓRICO E INDUSTRIAL.....
2.1.	CONCEPTOS BÁSICOS DE LA CARACTERIZACIÓN DE ROCA Y MACIZO ROCOSO.....
2.1.1	<i>Roca Intacta</i>
2.1.2	<i>Sistemas de clasificación de macizo rocoso</i>
2.2	PERFORACIÓN Y TRONADURA
2.2.1	<i>Diseño de perforación y tronadura</i>
2.2.1.1	Explosivos químicos y sus propiedades
2.2.1.2	Diseño mallas de perforación y tronadura.....
2.2.1.3	Diseño de la secuencia de encendido de la tronadura
2.2.2	<i>Rotura de roca durante la detonación</i>
2.3	MODELOS EMPÍRICOS MÁS UTILIZADOS EN LA INDUSTRIA
2.3.1	<i>Modelo Kuz-Ram (2005)</i>
2.3.2	<i>Crush Zone Model</i>
2.3.3	<i>Kuznetsov-Cunningham-Ouchterlony Model (2005)</i>
2.4	MEDICIÓN DE FRAGMENTACIÓN
2.5	MODELOS PREDICTIVOS CON MATLAB
2.5.1	<i>Preprocesamiento de datos</i>
2.5.1.1	Tratamiento de datos atípicos y datos faltantes
2.5.1.2	Normalización
2.5.1.3	Selección de características para predictores
2.5.2	<i>Entrenamiento de algoritmos</i>
2.5.3	<i>Modelos de Regresión</i>
2.5.4	<i>Validación y medidas de ajuste</i>
2.5.4.1	Raíz del error cuadrático medio
2.5.4.2	Coefficiente de determinación.....
2.5.4.3	Gráficos de Validación
2.6	GESTIÓN DE LA FRAGMENTACIÓN EN LA INDUSTRIA
2.6.1	<i>Ciclo Planifica-Hacer-Verifica-Actuar enfocado a la perforación y tronadura</i>
2.6.1.1	Planificar
2.6.1.2	Hacer
2.6.1.3	Verificar
2.6.1.4	Actuar.....
2.6.2	<i>Factores que podrían condicionar la estimación de fragmentación</i>
2.6.2.1	Representatividad de la información.....
2.6.2.2	Procesamiento de la información

2.6.2.3	Modelos predictivos para la estimación de fragmentación	33
3	DESARROLLO.....	34
3.1	CASO DE APLICACIÓN.....	34
3.1.1	<i>Unidades Geotécnicas en Mina Los Pelambres.....</i>	<i>34</i>
3.2	EXPLORACIÓN DE DATOS.....	36
3.2.1	<i>Base de datos.....</i>	<i>36</i>
3.2.1.1	Parámetros de Diseño	¡Error! Marcador no definido.
3.2.1.2	Parámetros de roca ausentes.....	¡Error! Marcador no definido.
3.2.2	<i>Comportamiento de las variables en la base de datos</i>	<i>37</i>
3.2.3	<i>Procesamiento de datos.....</i>	<i>41</i>
3.2.3.1	Datos Atípicos y faltantes	41
3.2.3.2	Normalización de datos.....	41
3.2.3.3	Selección de características.....	42
3.3	ESTIMACIÓN DE FRAGMENTACIÓN UTILIZANDO MODELOS EMPÍRICOS	43
3.3.1	<i>Kuz-Ram.....</i>	<i>43</i>
3.3.2	<i>KCO</i>	<i>43</i>
3.4	ESTIMACIÓN DE FRAGMENTACIÓN CON ALGORITMOS DE MÁQUINAS DE APRENDIZAJE	44
3.4.1	<i>Entrenamiento de algoritmos sin normalizar base de datos</i>	<i>44</i>
3.4.2	<i>Estimación de fragmentación con base de datos normalizadas.....</i>	<i>46</i>
4	ANÁLISIS DE RESULTADOS	50
4.1	RESULTADOS DE LA ESTIMACIÓN DE FRAGMENTACIÓN CON MODELOS EMPÍRICOS	50
4.2	ESTIMACIÓN DE FRAGMENTACIÓN UTILIZANDO MÁQUINAS DE APRENDIZAJE	51
4.2.1	<i>Estimación de fragmentación utilizando variables normalizadas.....</i>	<i>53</i>
5	CONCLUSIONES Y RECOMENDACIONES.....	56
REFERENCIAS	61	
ANEXOS	67	
RESUMEN FACULTAD DE INGENIERÍA.....	¡ERROR! MARCADOR NO DEFINIDO.	

ÍNDICE DE TABLAS

Tabla 1: Propiedades de unidades geotécnicas en Mina Los Pelambres [53]	¡Error! Marcador no definido.
Tabla 2: Comparación de información entre modelos y base de datos	36
Tabla 3: Correlaciones entre variables predictoras y P50	42
Tabla 4: P-value para variables con comportamiento irregular	43
Tabla 5: Lista de variables y sus abreviaciones	44
Tabla 6: Bitácora de entrenamiento de algoritmos	45
Tabla 7: Bitácora de entrenamiento con base de datos zscore	46
Tabla 8: Bitácora de entrenamiento con base de datos range	47
Tabla 9: Estimación de fragmentación utilizando modelos empíricos	50
Tabla 10: Resultados de estimación de 5 mejores modelos entrenados	51
Tabla 11: Resultados estimación utilizando base de datos normalizada zscore	54
Tabla 12: Resultados estimación utilizando base de datos normalizada range	54



ÍNDICE DE FIGURAS

Figura 1: Diagrama de proceso para la extracción y procesamiento de minerales	1
Figura 2: Árbol de objetivos	¡Error! Marcador no definido.
Figura 3: Proceso de detonación [24].....	13
Figura 4: Distribución de tamaños en material ROM [30].....	17
Figura 5: Determinación de la fragmentación [33]	20
Figura 6: Procesamiento digital de imágenes.....	21
Figura 7: Proceso de la información para la generación de modelos predictivos [42]	22
Figura 8: Esquema de algoritmos de Machine Learning [42]	25
Figura 9: Interfaz de configuración del Regression Learner [41]	26
Figura 10: Estadísticas de un modelo entrenado en el Regression Learner [41].....	28
Figura 11: Ciclo PHAV enfocado a la perforación y tronadura	30
Figura 12: Ubicación del complejo minero Los Pelambres	34
Figura 13: Histogramas de las variables presentes en "datos2"	39
Figura 14: Gráfico comparativo de la estimación utilizando modelos empíricos con respecto a la variable original.....	50
Figura 15: Gráfico comparativo de capacidad estimativa de modelos entrenados con ML	51
Figura 16: Gráfico comparativo de capacidad estimativa de modelos empíricos y modelos entrenados	52
Figura 17: Gráficos "Real vs. Estimado" para los modelos empíricos y entrenados.....	53
Figura 18: Gráficos "Real vs Estimado" para bases normalizadas	55

NOMENCLATURA

ACB:	Ángulo de cara de banco, es el ángulo que se forma entre la cara de banco y la horizontal.
B:	Burden, distancia nominal entre dos filas de pozos consecutivas.
CZM:	Crush Zone Model
E:	Módulo de Young, corresponde a una medida de la elasticidad de la roca.
H:	Altura de banco
KCO:	Modelo Kuznetsov-Cunningham-Ouchterlony
KR:	Modelo Kuznetsov-Rammler
MAE:	Mean absolute error, corresponde al error absoluto medio de la estimación.
ML:	Machine Learning
MSE:	Mean square error, corresponde al error cuadrático medio de la estimación.
MWD:	Measurement while drilling o medición durante la perforación
P50:	Diámetro efectivo del 50% pasante en masa de una curva granulométrica.
PHVA:	Ciclo de mejora continua planifica-hacer-verificar-actuar.
PF:	Powder factor o factor de carga, relación entre la masa de explosivo y la masa de roca.
R ² :	Bondad de ajuste, entrega una medida de la calidad del ajuste de la estimación.
RMSE:	Root mean square error, corresponde a la raíz cuadrada del MSE.
ROM:	Run of mine, corresponde a material tronado sin haber pasado por un proceso de chancado ni conminución.
S:	Spacing, distancia entre tiros de una misma fila.
SCADA:	Supervisory Control And Data Acquisition
Te:	Tiempo entre pozos consecutivos de una misma fila.
UCS:	Resistencia a la compresión uniaxial de la roca intacta.
UGT:	Unidad geotécnica.
v:	Razón de Poisson.
VOD:	Velocidad de detonación.
V _p :	Velocidad de la onda P en la roca.
ρ:	Densidad de la roca.

1 INTRODUCCIÓN

1.1 CONTEXTO GENERAL Y ESTADO DEL ARTE

Dentro de los procesos operativos que realiza la minería para la extracción de los minerales se encuentra la tronadura, la cual es el mecanismo más eficiente en términos energéticos y económicos para fragmentar la roca hospedante y favorecer la extracción de estos recursos [1]. Es por esto que un diseño eficiente del proceso para producir fragmentación *run of mine* (ROM) puede tener consecuencias no solo en lo que respecta a granulometría, sino que también, puede significar un aumento de eficiencia y desempeño de la operación minera [2] [3] [4]. En base a esto se puede decir que, la fragmentación es fundamental para la operación debido al gran impacto que puede llegar a tener en la continuidad del proceso minero, en el carguío, transporte y procesamiento de material como se puede ver en la Figura 1 [3].

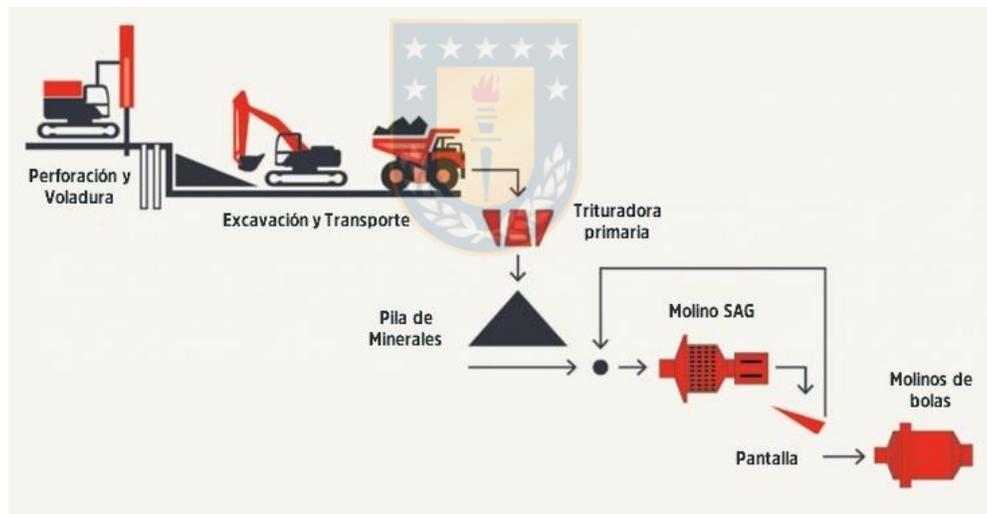


Figura 1: Diagrama de proceso para la extracción y procesamiento de minerales.

Siendo la fragmentación un elemento fundamental dentro de la operación, surge la necesidad de realizarle seguimiento y mantenerla controlada [5]. En este contexto, los métodos para medir la fragmentación han evolucionado a lo largo de la historia, partiendo desde el tamizaje, hasta modernos sistemas de análisis de imágenes utilizando configuraciones binoculares o escáneres láser, para reconstruir de manera más fidedigna las pilas de material y su granulometría [6]. Sin embargo, hace unos cuantos años que fue imprescindible contar con herramientas que permitieran predecir los resultados granulométricos de la tronadura, para lo que se desarrollaron una serie de ecuaciones

matemáticas a partir de datos experimentales, con la intención de poder estimar la fragmentación obtenida bajo ciertas condiciones, estas ecuaciones reciben el nombre de modelos empíricos.

Independiente de las constantes investigaciones y progresivas modificaciones de los modelos existentes, aún se busca un mejor desempeño en la predicción de finos y una mayor exactitud de la estimación, puesto que en la práctica los modelos empíricos utilizados para esta tarea no tienen un buen ajuste, lo que impide obtener los resultados necesarios a nivel industrial para cumplir con los objetivos de la operación [7] [8]. Un ejemplo de esto es el *Kuznetsov-Cunningham-Ouchternoly Model* (KCO), que plantea la utilización de la función de Swebrec para unificar la distribución de fragmentación, producto tanto de la tronadura a cielo abierto como también del proceso de conminución, el que actualmente no ha alcanzado una exposición masiva que facilite en términos prácticos su aplicación en la industria [9].

Por su parte, el aún más reciente modelo Múltiple Blasthole Fragmentation Model (MBF) desarrollado durante el año 2015, estudia el proceso de la detonación como un proceso dinámico, considerando la interacción de las ondas de choque producidas por la activación de las cargas, y cómo es que esta se relaciona con la generación de fracturas. Lamentablemente en consecuencia a su reciente desarrollo y constante perfeccionamiento, aún no existen suficientes evidencias de que esta nueva forma de analizar la tronadura presente resultados superiores a los métodos actualmente utilizados [10] [11] [12].

De acuerdo con lo anterior, es que diversos autores han venido realizando estudios en la materia, con el propósito de obtener buenos resultados en fragmentación, y que estos a su vez, permitan optimizar los procesos industriales. En cuanto a ello, la incorporación de algoritmos de *Machine Learning (ML)* y otras herramientas de la inteligencia artificial (IA) pueden mejorar la estimación de la fragmentación producto de la tronadura mediante el entrenamiento y desarrollo de modelos predictivos [4] [13] [14] [15]. Teniendo en consideración lo anterior, es que se planea realizar esta comparación de desempeño entre los modelos empíricos más comúnmente utilizados y algunos de estos algoritmos de *ML* para la estimación de fragmentación producto de la tronadura en minería a cielo abierto.

1.2 PROPÓSITO FUNDAMENTAL Y NATURALEZA DE LA INVESTIGACIÓN

El presente trabajo surge a partir de la posibilidad de obtener mejores resultados en la estimación de la fragmentación, obtenida mediante modelos semiempíricos comúnmente utilizados, aprovechando los recursos computacionales y de la inteligencia artificial actualmente disponibles. Por lo que el

principal objetivo fue indagar en si la estimación de fragmentación, específicamente el P50 de la distribución granulométrica, podría ser eventualmente mejorada mediante la incorporación de algoritmos de ML, a través de la programación en MATLAB para generar modelos predictivos entrenados para una base de datos. Esto dió paso a una **investigación aplicada**, por ende, en una primera instancia, se debió realizar una investigación con la finalidad de entrar en contexto de las herramientas y los procedimientos actualmente utilizados para esta materia en la industria, y en una segunda etapa efectuar el entrenamiento, estimación y evaluación de esta metodología.

1.3 HIPÓTESIS DE TRABAJO

El desempeño de los modelos predictivos más utilizados en la industria para estimación de fragmentación de rocas producto de la tronadura, podría ser eventualmente mejorado mediante la incorporación de algoritmos de *Machine Learning* para el desarrollo de modelos predictivos. Esto en base a la información disponible dentro de una operación minera, teniendo en consideración su representatividad (cantidad y calidad de datos), recursos económicos, tecnológicos, valoración de las oportunidades y del tiempo experto, entre otros.

1.4 OBJETIVOS

A continuación, se muestra un esquema que representa el árbol de objetivos del presente trabajo. En primer lugar, de izquierda a derecha, se encuentra el nombre de la investigación. En segundo lugar, los objetivos generales (3 objetivos generales) y, por último, los objetivos específicos que permitieron concretar cada objetivo general vinculado según muestra la **¡Error! No se encuentra el origen de la referencia..** Entre paréntesis se encuentra detallado la sección del presente informe dentro del cual se aborda el objetivo respectivo.

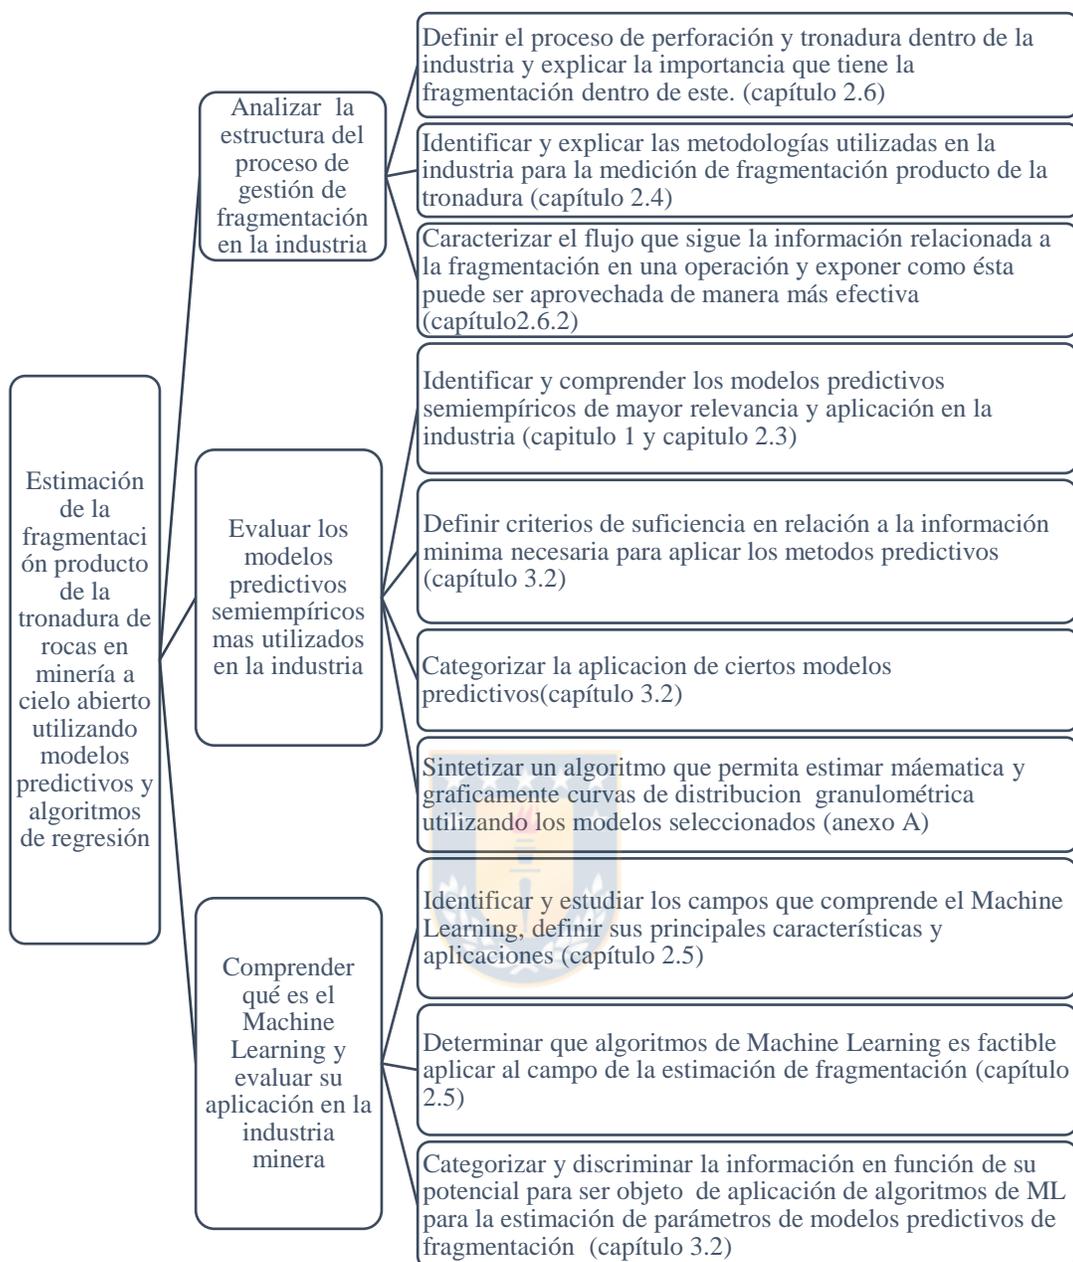


Figura 2: Árbol de objetivos

1.5 ALCANCES Y LIMITACIONES

El presente trabajo estará enfocado en la estimación de fragmentación producto de la tronadura en minería metalífera de sulfuros de cobre a cielo abierto, específicamente en la estimación del P50 de la distribución granulométrica, los modelos que lo estiman, los parámetros mínimos requeridos, el entrenamiento y, por último, la evaluación de algoritmos para la generación de nuevos modelos predictivos de la variable anteriormente mencionada.

Una de las principales limitaciones de la investigación es lo referido al acceso a la información. Contar con una base de datos que contuviera datos de diseño, explosivo, caracterización de roca y granulometría, que permitiese estimar la fragmentación utilizando modelos semiempíricos y, posteriormente entrenar algoritmos de ML para poder realizar una comparación entre el desempeño de ambos métodos, fue una de las barreras que mayor tiempo requirió para ser superada. Lo anterior, obedece a los criterios de acceso a las fuentes de información y datos, debido al interés estratégico y de resguardo de las empresas que participan dentro de una operación minera, siendo estas de **difícil acceso y/o acceso restringido**.

En segundo lugar, se encuentra la representatividad de la información disponible, puesto que esta no siempre es un fiel reflejo de lo que ocurre en terreno, asimismo ciertas variables son el resultado del promedio de las mediciones, por lo que no fue posible contar con toda la información. En la misma línea, la ausencia de variables como la velocidad de onda P (V_P) y la descripción de los sets de discontinuidades (espaciamiento, orientación, etc.) que permitieran el cálculo o aproximación del factor de roca (A), limitaron la estimación con modelos como el CZM.

Finalmente, el contexto investigativo resultó ser inusualmente complejo, en ese sentido el actual escenario de pandemia mundial implicó establecer medidas preventivas, protocolos de resguardo y confinamiento social como política sanitaria nacional, la que se mantuvo durante el año 2020 en las diferentes localidades y regiones de nuestro territorio. Situación que limitó ciertas interacciones y el acceso a información de campo. Sin embargo, esta situación dio paso a la utilización de plataformas digitales como Zoom y Google Meet que permitieron tomar contacto y entrevistar a diferentes profesionales del área de la minería, lo que enriqueció enormemente el trabajo.

1.6 METODOLOGÍA

En lo que respecta a la metodología del trabajo, al tratarse de una investigación aplicada, la metodología incorporó aspectos cualitativos durante la revisión bibliográfica y el análisis de los resultados obtenidos durante el desarrollo del proceso. Sin embargo, también incorporó aspectos de corte cuantitativo, porque culmina con el análisis de datos duros obtenidos de la comparación entre los resultados de estimación.

En primera instancia, se realizó una exhaustiva revisión bibliográfica que englobó el estudio de los modelos para la estimación de fragmentación, su evolución y aplicación en la industria minera; Adicionalmente, también se investigó la aplicación de la inteligencia artificial para la estimación y, la gestión de la información de fragmentación dentro de una operación. Simultáneamente, se desarrollaron una serie de entrevistas con variados profesionales y expertos en las áreas de la perforación y tronadura, estimación de fragmentación, procesamiento y análisis de datos y, por último, gestión de la fragmentación. Posteriormente se debió realizar una capacitación con el objeto de poder desarrollar la parte aplicada de la investigación, para lo cual se utilizó el programa MATLAB, con el que fue posible programar un código para estimar la fragmentación utilizando las ecuaciones de los modelos y posteriormente, entrenar algoritmos empleando una base de datos y la aplicación *Regression Learner*. Finalmente, se procedió a importar la base de datos, analizarla, utilizarla para estimar, comparar y finalmente, concluir al respecto.

2 CONTEXTO TEÓRICO E INDUSTRIAL

2.1. CONCEPTOS BÁSICOS DE LA CARACTERIZACIÓN DE ROCA Y MACIZO ROCOSO

2.1.1 Roca Intacta

Las rocas son un agregado de minerales que conforman la parte sólida de la corteza terrestre, formada por bloques sólidos y duros, de gran tamaño, encajados y ligados entre sí. Al estudiar el comportamiento mecánico de las rocas, estas son generalmente heterogéneas, discontinuas y anisotrópicas, cuyas propiedades físicas y mecánicas de la roca varían con la escala de observación. Algunas de estas propiedades son utilizadas para la estimación de la fragmentación, por lo que se describirán brevemente a continuación.

- Resistencia a la Compresión: corresponde al valor del esfuerzo compresivo máximo que un material puede resistir antes de su rotura. Ésta, generalmente es determinada mediante la prueba de compresión uniaxial (UCS por su sigla en inglés) debido a su confiabilidad en los resultados de resistencia y fractura de la roca [16].
- Resistencia a la Tensión: corresponde a la tensión máxima a la que puede someterse un material antes de su rotura. Generalmente, se estima de manera indirecta mediante el Brazilian Tensile Strength (BTS) a causa de su complejidad para ser medida directamente [17].
- Módulo de Young (E): denota la elasticidad de la roca, puesto que es la pendiente en la curva esfuerzo-deformación. A partir de esta curva, es posible obtener más de un módulo de Young en consecuencia al comportamiento dinámico de la roca, pero el más utilizado es la pendiente obtenida en el origen de la curva, puesto a que este es el más preciso conforme a los resultados de laboratorio [18].
- Razón de Poisson: es una constante elástica que proporciona una medida del estrechamiento de sección de un prisma de cierto material, la cual se da entre la deformación transversal y longitudinal de su sección [19].
- Velocidad de Onda P: corresponde a la velocidad de propagación de la onda primaria longitudinal compresiva producida por la perturbación termodinámica de la detonación. Es una función de las propiedades elásticas (módulo de compresibilidad y rigidez) y de la densidad de la roca.

2.1.2 Sistemas de clasificación de macizo rocoso

El macizo rocoso es la composición formada por roca intacta, discontinuidades y fracturas presentes en la estructura. Para su clasificación existen varios sistemas desarrollados para diferentes necesidades. A continuación, se mencionan los 3 sistemas de clasificación más comunes y de los cuales se puede desprender información para definir parámetros en los modelos.

- **Geological Strength Index (GSI)**: se obtiene a partir de una tabla que considera dos factores, por un lado, la fragmentación *in situ* del macizo y, por otro lado, la condición o calidad de la superficie de las discontinuidades. El GSI es un índice que va de 0 a 100 para calificar el macizo rocoso, donde 0 corresponde a un macizo altamente meteorizado y desintegrado por la baja cohesión entre sus bloques. Por el contrario, un valor de 100 corresponde a un macizo rocoso casi sin discontinuidades. Requiere un nivel alto de entrenamiento práctico del geólogo, por ende, este es quién establece la calificación de manera visual tras un peritaje en terreno [20].
- **Rock Quality Designation (RQD)**: es un indicador de la fragmentación natural de la roca en base a un sondaje estándar. Este se representa en porcentaje donde mientras más cercano a 100 sea este porcentaje, el macizo será de mayor calidad [21].
- **Rock Mass Rating (RMR)**: es un indicador geomecánico desarrollado por Bieniawski que considera aspectos como el UCS, RQD, espaciamiento, orientación y condición de las discontinuidades y presencia de aguas subterráneas. Estos aspectos se puntúan arrojando 5 categorías de macizo, donde el de mayor puntaje, se presume, es de excelente calidad [21].

2.2 PERFORACIÓN Y TRONADURA

2.2.1 Diseño de perforación y tronadura

“Los parámetros de diseño tales como bordo, taco, sub-barrenación, espaciamiento y tiempo de iniciación, deben ser calculados cuidadosamente para que una voladura funcione de manera eficiente, segura y con niveles de vibración y golpe de aire razonables” [22].

2.2.1.1 Explosivos químicos y sus propiedades

Un explosivo es una sustancia compuesta por una parte combustible y otra oxidante que, al sufrir una perturbación externa, reacciona químicamente liberando gases y calor en grandes cantidades dentro de un breve intervalo de tiempo [23]. Las principales propiedades de un explosivo para fines de fragmentación son las que se definen a continuación y, la relación que estas guardan con la fragmentación se explican en mayor detalle en la sección 2.2.2.

- **Velocidad de Detonación**: corresponde a la velocidad a la cual la reacción se mueve a lo largo de la columna de explosivo. Esta puede utilizarse como una herramienta para determinar la eficiencia de una reacción explosiva.
- **Densidad**: corresponde a la relación entre la masa y el volumen ocupado por el explosivo, esta es importante debido a que los explosivos se compran, almacenan y utilizan sobre la base del peso, además, la densidad limita el peso del explosivo que se puede cargar dentro de un diámetro específico de tiro.
- **Presión de Detonación**: corresponde a la presión obtenida de manera casi instantánea como resultado del movimiento de la onda de choque. La presión de detonación se estima en base a la densidad del explosivo y la velocidad de la reacción.
- **Volumen de Gases**: corresponde a los litros de gas generados por un kilogramo de explosivo, este volumen dependerá de la composición química del mismo.
- **Energía**: la energía liberada por un explosivo tiene dos componentes, la **energía de gases** y la **energía de la onda**. En general, es difícil de caracterizar, por lo que se utiliza la “potencia relativa” que se entrega en porcentaje con respecto a un explosivo patrón, esta puede ser en peso o en volumen.
- **RWS**: o también conocida como *potencia relativa en peso*, corresponde a la relación de la energía relativa por unidad de peso (cal/g) entre un explosivo de interés, con respecto a un

explosivo patrón. Generalmente se utiliza el ANFO como explosivo patrón, al que se le asigna un RWS de 100%. En usos militares, se utiliza el TNT como referencia, donde el RWS del ANFO con respecto del TNT es 115%.

- **Potencia Rompedora:** corresponde a la capacidad del explosivo de romper la roca. Se mide en función de la rapidez con la que un explosivo incrementa la presión en el pozo en estado confinado. Si dos explosivos tienen la misma energía relativa, la que tenga mayor potencia rompedora fragmentará la roca en fragmentos de menor tamaño [24].

2.2.1.2 *Diseño mallas de perforación y tronadura*

Una malla de perforación corresponde a un patrón geométrico donde se establece el número de tiros, el número de filas, distancia a la cara libre (burden) y espaciamiento entre estos. Dentro de una malla de perforación existe una serie de parámetros que se definen con la intención de minimizar el daño generado a la roca y optimizar la fragmentación. A continuación, se mencionan las variables de diseño más relevantes para la estimación y control de la fragmentación [22].

- **Burden:** generalmente se refiere como burden al *burden nominal*, que se define cómo la distancia por diseño que existe entre filas de tiros. También existe el *burden real*, que corresponde a la distancia efectiva entre la cara libre y los tiros al momento de detonar. La diferencia entre estos dos tipos de burden se aprecia de manera más clara en secuencias de tronadura en “V”. De todas las dimensiones de diseño en una voladura, el burden es la más crítica debido a que la relación que tiene con la altura de banco puede condicionar la fragmentación. Otras variables de diseño son más flexibles y no producirán diferencias tan drásticas en los resultados cómo la misma proporción de error en la dimensión del burden [22].
- **Espaciamiento:** corresponde a la distancia entre tiros de la misma fila, este tendrá influencia en la distribución de las fracturas radiales producidas durante la detonación. Un espaciamiento demasiado pequeño provocará una interacción entre fracturas radiales mayor a la deseada, lo que se traducirá en una pulverización excesiva de la roca alrededor del tiro. El espaciamiento será función de la rigidez del banco y de la secuencia de detonación.
- **Diámetro del tiro:** corresponde al diámetro de los tiros a perforar, donde posteriormente se cargará explosivo para la tronadura. La selección del diámetro adecuado del barreno para cualquier trabajo requiere considerar factores vinculados a la fragmentación, vibraciones del terreno, material particulado en suspensión provocado y aspectos económicos de la perforación.

- **Altura de banco**: la altura de banco corresponde a la distancia que existe verticalmente entre niveles de trabajo, esta es función del equipo de carguío que se utilice.
- **Longitud del tiro**: corresponde a la longitud total de la perforación, esta incluye la altura de banco y la pasadura o sobre perforación para mantener la nivelación del piso.

Estas variables suelen definirse teniendo en cuenta factores geológicos, condiciones operativas y de seguridad. Sin embargo, existe una relación entre altura de banco y burden conocida como relación de rigidez o esbeltez (H/B) que funciona como guía para para estimar de manera preliminar consecuencias de la tronadura como es la fragmentación y el desplazamiento de material a través de la generación de ciertos rangos para el valor de la relación [24]. Si la relación H/B es menor a 3, se obtendrá una fragmentación gruesa con problemas de sobre excavación. Estos efectos disminuirán a medida que el valor de esta relación aumente y alcance cifras iguales o superiores a 3.

2.2.1.3 Diseño de la secuencia de encendido de la tronadura

Una plantilla de tronadura consiste en una secuencia de detonación de explosivos ubicados según una malla de perforación. La selección del tiempo de iniciación adecuado es tan importante en cada aspecto, cómo la selección de las dimensiones físicas tales como burden nominal, burden real y espaciamiento, debido a que el tiempo de iniciación determina que tiros detonarán de manera simultánea y que tiros serán consecutivos. Existe más de una configuración de secuencia, cada una consta de ciertas características como por ejemplo el orden en que los tiros detonan, la dirección en que se proyecta la roca tronada y las consecuencias de la tronadura en general. En base a esto, la determinación del sistema de iniciación de los tiros será determinante, puesto que, si se controla la dispersión en el tiempo de detonación, posible gracias a la utilización de detonadores electrónicos, también se tendrá un mayor control de las cargas tiro a tiro. Lo anterior tendrá impacto sobre la fragmentación, ya que condicionará la interacción entre las ondas de choque generadas por la detonación de las cargas y, por su parte, también se verán consecuencias sobre las vibraciones y el costo de los insumos [24] [22]. El principal desafío de la perforación y tronadura consiste en equilibrar las consecuencias de la tronadura en post de aprovechar las oportunidades de obtener una granulometría que optimice el proceso, pero a su vez, reducir los efectos negativos como son las vibraciones y el material particulado en suspensión producido. Estas variables funcionan de manera inversa, es decir a medida que se obtiene una granulometria más fina y uniforme, las vibraciones y el material en suspensión se ven aumentados. Por lo que en el diseño de mallas de perforación y

tronadura es el principal objetivo buscar un punto que optimice estas tres variables anteriormente mencionadas o que, en su defecto, minimice el daño general producido [1].

2.2.2 Rotura de roca durante la detonación

La tronadura es el resultado de la detonación de una carga explosiva que produce una perturbación termodinámica, la cual se agrupa en dos etapas. Durante la primera etapa se ocasiona la rotura de roca producida por la compresión de esta y la expansión de la onda de choque, la que alcanza una presión que supera la resistencia a la compresión en un área cercana circundante al pozo, el cual se sobre presuriza, y provoca que la roca no falle en el punto más débil de la pared. En lugar de ello, fallará simultáneamente en muchos puntos generando una serie de fracturas radiales. Estas fracturas radiales formaran cuñas que funcionaran como columnas con las dimensiones del burden y la altura de banco. Si la relación de rigidez aumenta por sobre valores estandarizados, la resistencia de estas columnas disminuirá provocando una mayor fragmentación que la deseada.

La segunda etapa, tiene lugar una vez que ha ocurrido el agrietamiento radial, donde la onda continúa viajando hasta el punto de alivio o la línea de menor resistencia, donde esta onda se refleja y continúa su desplazamiento, en esta parte del trayecto la energía que transporta y la presión que aún ejerce la onda de choque, supera la resistencia a la tensión de la roca y genera nuevos fragmentos. A continuación, se muestra un esquema que representa el proceso de la propagación de la onda durante el proceso de la detonación en la Figura 2; **Error! No se encuentra el origen de la referencia.** [22] [23] [24].

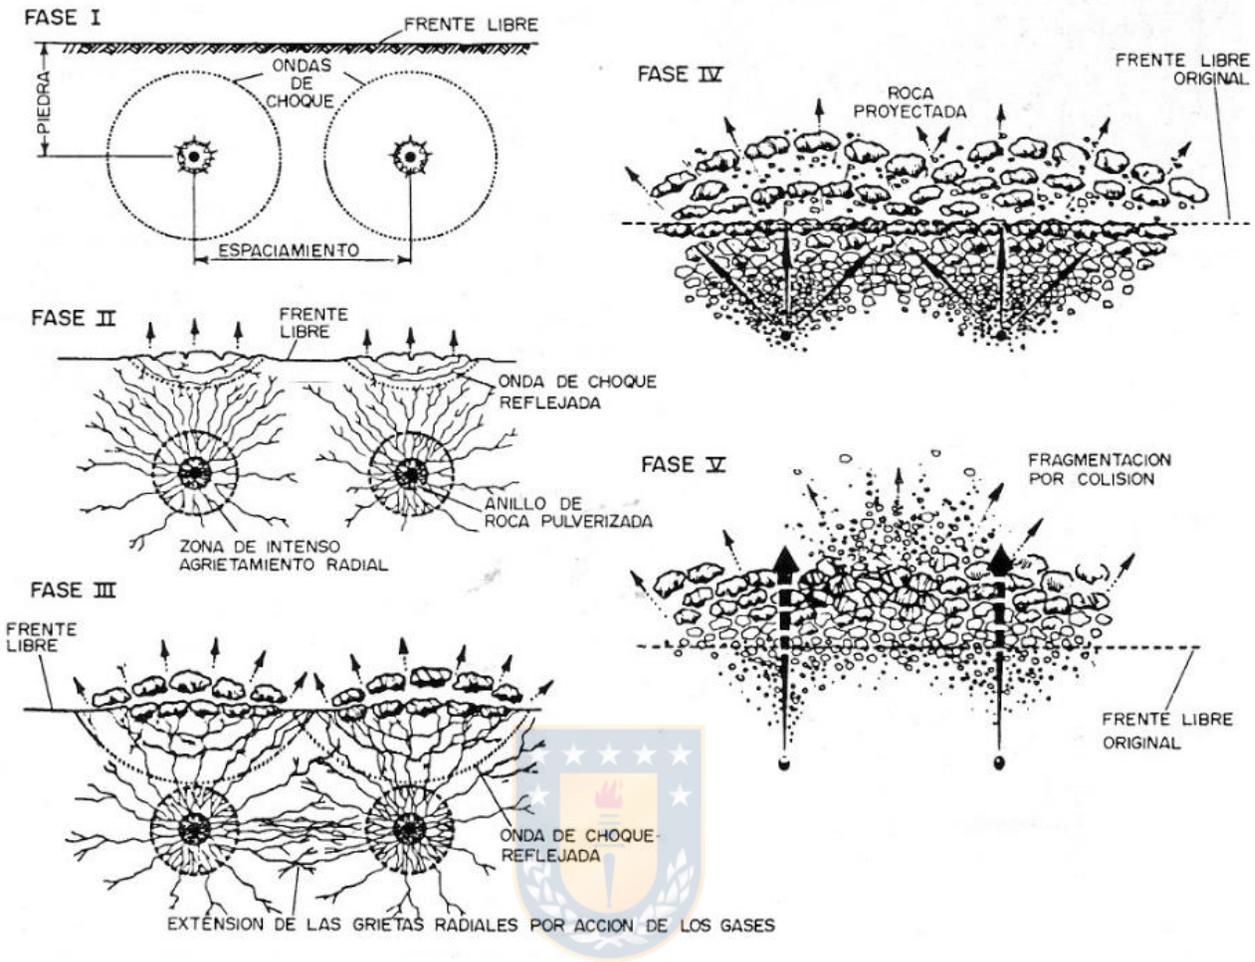


Figura 2: Proceso de detonación [24]

En vista de lo anterior es posible comprender que existe más de una variable relacionada a la eficiencia de la tronadura en términos de la obtención de una fragmentación deseada, por lo que existe una serie de estudios destinados a entender cómo es la relación de estas con la fragmentación. Algunas de las conclusiones importantes de estas investigaciones se mencionan a continuación.

- En lo que respecta a la resistencia de la roca, de acuerdo con un estudio realizado en Nigeria existe una buena correlación entre el UCS y la eficiencia de la tronadura en términos de fragmentación, es decir un mayor UCS se traduce en una menor fragmentación y, por ende, una menor eficiencia de la tronadura [25].
- Con respecto a las propiedades del explosivo, se puede determinar que un explosivo con mayor presión de detonación tendrá un mayor impacto en la fragmentación en términos de una menor granulometría que uno con una presión menor, a pesar de que ambos puedan tener la misma equivalencia en peso al ANFO [26]. Por otro lado, una reducción en la velocidad de detonación

(VOD) puede producir una menor presión de detonación que se traduce en una disminución de finos que, puede tener repercusiones en las fases siguientes del procesamiento de materiales [27].

- La relación entre impedancias es una medida de la eficiencia en la transmisión de energía del explosivo a la roca durante la detonación. Esta se calcula según muestra la ecuación 2.1, como una relación entre la impedancia del explosivo (numerador, donde ρ_e corresponde a la densidad del explosivo en kg/m^3 y VOD a la velocidad de detonación en m/s) y la impedancia de la roca (denominador, donde ρ_r es la densidad de la roca en kg/m^3 y V_p la velocidad de la onda P en la roca en m/s). A medida que esta relación se acerca a 1, la presión empleada en el pozo se acerca al valor de la presión generada por la detonación, por lo que se vuelve más eficiente en términos de la transmisión de energía del explosivo a la roca. Sin embargo, si esta relación alcanza valores muy superiores a 1, o en su defecto, muy inferiores a 1, se producirá una pérdida en la transmisión de la energía. La relación de impedancias permitirá discernir entre un explosivo u otro en función de los resultados de fragmentación que se desean obtener según las condiciones de roca. Por ejemplo, si se desea obtener una mayor fragmentación se optará por un explosivo que maximice la relación entre impedancias, ya que esto favorecerá la transmisión de energía lo que, en teoría, significa una mayor fragmentación de la roca [1].

$$n_z = \frac{\rho_e \cdot VOD}{\rho_r \cdot Vp} \quad (2.1)$$

2.3 MODELOS EMPÍRICOS MÁS UTILIZADOS EN LA INDUSTRIA

Los modelos empíricos son el método más utilizado a diario en el diseño de tronadura a nivel industrial a pesar de la variedad de parámetros que estos consideran. Algunos de los modelos empíricos más utilizados para la predicción de la fragmentación, se describen brevemente a continuación [28].

2.3.1 Modelo Kuz-Ram (2005)

En 1983 Kuznetsov desarrolló una ecuación para determinar la probabilidad de que el diámetro de partícula se ubique entre un rango de tamaños. A partir de esto, y posterior a una serie de pruebas de campo, se llegó a la ecuación general semi empírica de Kuznetsov para determinar el tamaño medio de partícula en base a propiedades del explosivo y factor de carga (ecuación 2.2) donde:

$$X_{50} = AK^{-0.8}Q^{\frac{1}{6}}\left(\frac{115}{RWS}\right)^{\frac{19}{20}} \quad (2.2)$$

- A es un factor de roca que puede tomar los siguientes valores (7 – roca medio dura; 10 – roca dura pero fuertemente fracturada; 13 - roca muy dura, débilmente fracturada).
- K es el powder factor en kg de explosivo por metro cúbico.
- Q es la cantidad de explosivo utilizado en kg.
- RWS es la equivalencia en peso al ANFO.

Posteriormente y a partir de lo anterior, se adapta la función de distribución de Rosin-Rammler (ecuación 2.3) donde se considera como parámetro el tamaño medio de distribución y el índice de uniformidad (usualmente entre 0.7 y 2). En 1987 Cunningham formuló la ecuación de uniformidad (ecuación 2.4) y modificó el cálculo del factor de roca incorporando la influencia de las discontinuidades, de la densidad de roca, presencia de agua y caracterización de macizo rocoso mediante el RMR. (ecuación 2.5).

$$R = \exp\left[-0.693\left(\frac{x}{x_{50}}\right)^n\right] \quad (2.3)$$

- X_{50} corresponde al tamaño medio de la distribución granulométrica calculado con la ecuación de Kuznetsov.
- n el índice de uniformidad determinado por Cunningham.

$$n = \left(2.2 - 14 \left(\frac{B}{d} \right) \right) * \sqrt{0.5 \left(1 + \frac{S}{B} \right) * \left(1 - \frac{W}{B} \right) * \left(\frac{Abs(BCL - CCL)}{L} + 0.1 \right)} * \frac{L}{H} \quad (2.4)$$

- d corresponde al diámetro de tiro en mm.
- W es la desviación estándar de la perforación.
- BCL largo de la carga del fondo (m).
- CCL largo de la columna de carga (m).
- L largo de la carga (m).
- H alto de banco (m).

$$A = 0.06 * (RMD + RDI + HF) \quad (2.5)$$

- RMD es un numero asignado de acuerdo a la condición de la roca, este se determina en función de la condición de las discontinuidades (espaciamiento, orientación y presencia de agua).
- RDI influencia de la densidad.
- HF es un factor de dureza que se determina en función del modulo de elasticidad.

Años después, basándose en trabajos previos de Bergmann (1974) y Rosmanith (2003) donde evidencia la influencia del tiempo entre pozos en la fragmentación, es que se formula un nuevo factor para la ecuación de Kuznetsov (ecuación 2.6) que, considera la razón que hay entre el retardo entre pozos (T) y el retardo máximo para optimizar la fragmentación (T_{max}), este último se determina conforme muestra la ecuación 2.7 donde C_x corresponde a la velocidad de onda P en la roca medida en km/s.

$$A_T = 0.06 \left(\frac{T}{T_{max}} \right)^3 - 0.13 \left(\frac{T}{T_{max}} \right)^2 - 1.58 \left(\frac{T}{T_{max}} \right) + 2.1 \quad (2.6)$$

$$T_{max} = \frac{15.6 * B}{C_x} \quad (2.7)$$

Por último, con el pasar de los años se han propuesto una serie de modificaciones y mejoras al modelo sin mayor impacto en su desempeño. A pesar de ser el modelo de predicción más ampliamente utilizado en la actualidad gracias a su fácil parametrización y aplicación, este presenta fuertes carencias como son la estimación de finos y la consideración de que la energía producida por el explosivo en pozos adyacentes no interfiere [3] [29] [28].

2.3.2 Crush Zone Model

En 1999 en JKMRC toma cuerpo la hipótesis de que la pila de material es la mezcla del material fragmentado mediante dos mecanismos diferentes, los cuales se combinan para lograr la distribución granulométrica. Un primer set es originado de la parte del macizo relativamente cercano al tiro, cuyos fragmentos se producen por falla de corte compresivo y, un segundo set, típicamente mucho más grande que el primero, proveniente de la roca que está más alejada del tiro, generados por fallas de tensión y la extensión de las fracturas preexistentes en el macizo.

En base a lo anterior, se plantea que deben existir dos distribuciones granulométricas modeladas con la función de Rosin-Rammler, las que coinciden en el tamaño medio de la distribución granulométrica (P50) determinado con la ecuación de Kuznetsov como se muestra a continuación en la Figura 3. Donde se puede apreciar en una línea más oscura una distribución correspondiente a la parte más gruesa de la curva granulométrica y que utiliza los parámetros de distribución obtenidos para el modelo KR. Por otro lado, en la parte inferior se puede apreciar en gris, una sección de la curva granulométrica que corresponde a los fragmentos más finos de la pila. Esta sección de la curva es la que se presume es generada en las cercanías del pozo producto de la compresión por parte de la onda de choque. Cada una de estas curvas posee sus propios parámetros que le otorgan su forma y puntos de inflexión, a su vez estas se unen en el X50 obtenido con la ecuación (2.2)

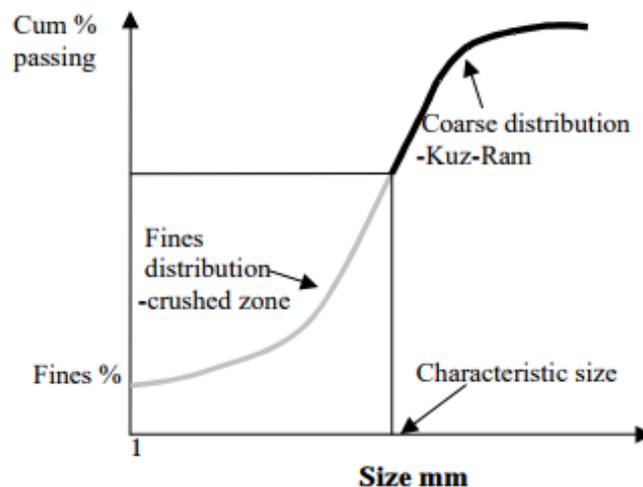


Figura 3: Distribución de tamaños en material ROM [30]

Lo relevante de este modelo, es que, como se mencionó anteriormente, la distribución de gruesos se modela siguiendo KR, la distribución de finos considera su propio índice de uniformidad (n_f) y un punto de inflexión de finos (f_c) que establece el porcentaje de material pasante bajo 1mm de diámetro,

debido a que se presume este sería el tamaño de partícula más grueso esperado a ser generado durante etapas de compresión cerca del pozo.

El cálculo de los parámetros de la distribución de gruesos es el mismo que en el KR utilizando las ecuaciones (2.2) y (2.4), pero es diferente cuando se trata de la distribución de finos. En primer lugar, es necesario conocer el punto de inflexión, el cual se calcula según muestra la ecuación (2.8).

$$f_c = \frac{V_c + V_b}{V_t} * 100 - F_r \quad (2.8)$$

$$n_f = \frac{\ln\left(\frac{\ln(1 - f_c)}{-0,693}\right)}{\ln\left(\frac{1}{x_{50}}\right)} \quad (2.9)$$

Donde V_c es volumen de la *Crushed Zone* o zona pulverizada haciendo alusión a que es el volumen fragmentado por compresión, V_b es la contribución de volumen de la *Cracked Zone* o zona quebrada haciendo referencia al volumen fragmentado por tensión, V_t corresponde al volumen total asociado al pozo y F_r un factor de corrección producto de los finos generados por discontinuidades del macizo propiamente tal. Lo anterior es necesario para posteriormente determinar el índice de uniformidad para finos (ecuación 2.9) [8] [26] [31] [30] [32].

2.3.3 Kuznetsov-Cunningham-Ouchterlony Model (2005)

El modelo de Kuznetsov-Cunningham-Ouchterlony utiliza la función de Swebrec (ecuación 2.10) para modelar la distribución granulométrica. El tamaño medio de partícula está dado por la ecuación (2.11) que en esencia es la misma de KR con un factor adicional (ecuación 2.12) que aumenta la estimación de finos.

$$P(X) = \frac{1}{\left[1 + \frac{\ln\left(\frac{X_{max}}{x}\right)}{\ln\left(\frac{X_{max}}{X_{50}}\right)}\right]^b} \quad (2.10)$$

$$X_{50} = g(n) \cdot A \cdot K^{-0.8} \cdot Q^{\frac{1}{6}} \cdot \left(\frac{115}{RWS}\right)^{\frac{19}{20}} \quad (2.11)$$

$$g(n) = \frac{\ln(2)^{\frac{1}{n}}}{\Gamma\left(1 + \frac{1}{n}\right)} \quad (2.12)$$

$$b = 2 \ln(2) \ln\left(\frac{x_{max}}{x_{50}}\right) n \quad (2.13)$$

Adicionalmente, esta distribución se encuentra limitada en su parte superior por el tamaño de bloque *in situ* del macizo (X_{max}) y define su ondulación mediante la relación entre Swebrec y KR tras igualar las pendientes de ambas curvas en X50 (ecuación 2.13). Esta configuración del modelo le provee un mejor desempeño en la estimación de finos, específicamente en la sección de la curva inferior a los 20mm de diámetro [9].



2.4 MEDICIÓN DE FRAGMENTACIÓN

La fragmentación en la pila determina la eficiencia del proceso y de la recuperación del mineral; sin embargo, es necesario equilibrarla con otros efectos adversos de la tronadura como lo son las vibraciones. En estos casos, donde la fragmentación objetivo se consigue a costa de generar una nociva cantidad de vibraciones, se debería optar por mantener una fragmentación inferior a la deseada para favorecer la estabilidad de taludes y de las propiedades geotécnicas. De esta manera, es que ha sido tan relevante el desarrollo de la medición de fragmentación y, se ha producido una evolución en la forma en cómo esta se mide. En la Figura 4 se presenta un esquema resumen sobre los principales métodos de determinación de fragmentación y su clasificación general.

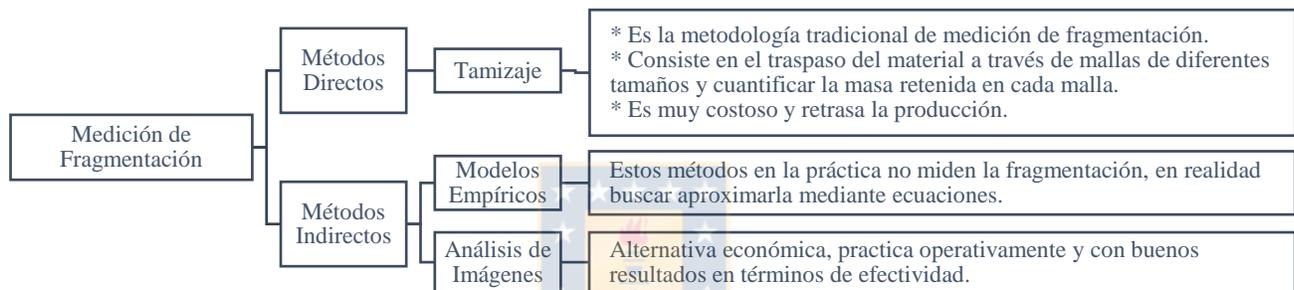
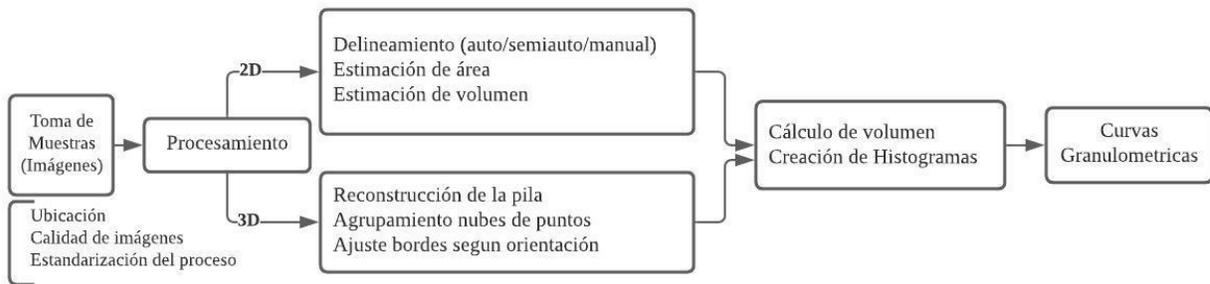


Figura 4: Determinación de la fragmentación [33]

Inicialmente el tamizaje era la única opción para conocer la distribución granulométrica de la pila, sin embargo, esto presenta dificultades operacionales debido al tiempo que toma, al impacto que esto tiene en la operación, y a su elevado costo. Por lo que actualmente se utiliza para estudios estratégicos y ensayos de laboratorio.

A partir de esta situación, es que surge el análisis digital de imágenes como una alternativa al tamizaje, en primera instancia esta tecnología presentó limitaciones en términos de la calidad y toma de muestras (dispositivos de baja resolución y dificultades en el control de la iluminación), así también en recursos computacionales para el procesamiento (memoria RAM, algoritmos de delineamiento, identificar espacios vacíos, identificar fragmentos finos, identificar sobreposición de fragmentos, etc.). Sin embargo, su efectividad dio una respuesta aceptable para la operación lo que permitió su aplicación y mejora constante hasta la fecha. A continuación, en la Figura 5 se muestra un esquema general de cómo es que se procesan las imágenes para medir la fragmentación.



*Figura 5: Procesamiento digital de imágenes
(Elaboración propia)*

En términos de los equipos que capturan las muestras, se ha visto un aumento en las resoluciones que son capaces de capturar, esto se traduce en una mayor cantidad de subunidades (píxeles) que facilitan el delineamiento durante el procesamiento. Por su parte, el acceso a la automatización ha permitido estandarizar el proceso de la toma de muestras controlando la iluminación y la captura secuencial de imágenes, llegando a generar disparos cada 3 minutos durante la excavación de una pila de material. Finalmente, las imágenes analizadas han logrado alcanzar la dimensión de profundidad, es decir, actualmente existen dispositivos capaces de capturar la pila de material tronado en 3 dimensiones mediante la simulación binocular, escáner laser, o utilizando técnicas de estructura de movimiento (SFM).

En lo que respecta al procesamiento de las imágenes, ha evolucionado desde el procesamiento manual bajo la responsabilidad de un operador, hasta el grado de la cuantificación automatizada de fragmentos y el cálculo de su masa, manteniendo la posibilidad de realizar un delineamiento manual, automático o semiautomático. En este proceso se han desarrollado una serie de software de diferentes orígenes (WípFrag, GoldSize, Split Desktop, KTH, FragScan, PowerSieve, Fraglyst3,0) tanto para su utilización desde un centro de control y procesamiento, así como para versiones portables en dispositivos móviles vía conexión inalámbrica. En conclusión, la incorporación de estos avances ha permitido mejorar la medición de fragmentación desde su instalación, configuración, resultados y confiabilidad [30] [33] [34] [6] [35] [36] [37] [38] [39] [40].

2.5 MODELOS PREDICTIVOS CON MATLAB

MATLAB es un programa computacional originalmente orientado al trabajo con arreglos matriciales, bases de datos, ciclos iterativos entre otros. Con el paso del tiempo ha incorporado diversas herramientas que facilitan la tarea de programar algoritmos cada vez más complejos de manera intuitiva e interactiva mediante el uso de funciones y aplicaciones como es el caso del *Regression Learner*, que permite el entrenamiento y comparación de diferentes algoritmos de regresión para la generación de modelos predictivos. A continuación, en la Figura 6 se muestra un esquema que resume el proceso que debe seguirse en general para desarrollar modelos predictivos utilizando MATLABO [41].

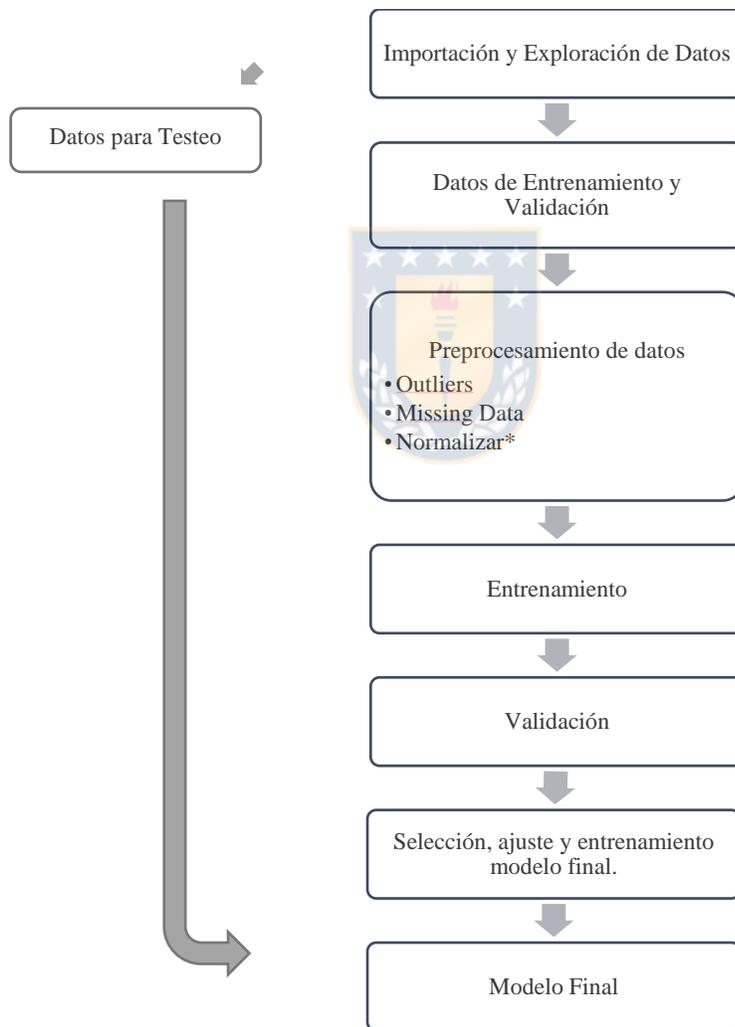


Figura 6: Proceso de la información para la generación de modelos predictivos [42]

2.5.1 Preprocesamiento de datos

Las bases de datos utilizadas para la generación de modelos predictivos deben ser pre procesados con la finalidad de tratar cierto tipo de anomalías que comúnmente se encuentran en ellos. Este tipo de problema corresponde al tratamiento de datos atípicos, datos inválidos y normalización de las variables presentes en la base de datos.

2.5.1.1 Tratamiento de datos atípicos y datos faltantes

Existen diversas formas de tratar con datos atípicos, un camino es la eliminación de las observaciones, otro puede ser la modificación de estas según algún criterio basado en las estadísticas de la variable y, otra opción es simplemente trabajar con los datos tal cual estos se presentan. Cada una de estas opciones debe ser analizada en función del tipo de variables y observaciones que estas almacenan puesto que estos datos pueden deberse a errores en el registro o anomalías interesantes de investigar, por lo que es necesario comprender parte del contexto de la información para optar por la mejor estrategia.

En lo que respecta a la presencia de datos faltantes tales como: datos que no son números (NaN), datos fuera de rango (inf) o datos simplemente ausentes o sin registro. También existen múltiples métodos para tratar este tipo de datos, pero estos se definen en función del tipo de invalidez [43].

2.5.1.2 Normalización

Es importante realizar la normalización cuando el orden de magnitud de las entradas sea diferente, por ejemplo, que una entrada tenga valores de varios órdenes de magnitud. En general las dos más comúnmente utilizadas para la normalización es la de *rango* 0-1 y la normalización *zscore*. En el primer caso, los valores normalizados se calculan de acuerdo con la ecuación (2.14).

$$x_{range} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.14)$$

Donde x es la variable no normalizada, x_{min} el valor mínimo de la variable a normalizar y x_{max} el valor máximo de la variable a normalizar. Para el caso de una normalización del tipo z-score, se utiliza la ecuación (2.15) donde μ corresponde a la media aritmética de la variable y σ a su desviación estándar.

$$x_{zscore} = \frac{x - \mu}{\sigma} \quad (2.15)$$

La elección de un método de normalización u otro no debería significar una diferencia sustancial a la hora de entrenar un modelo predictivo, sin embargo, dependiendo de la distribución estadística de las variables un método podría ser más o menos adecuado para llevar a cabo la normalización. En específico, si las variables tienen una tendencia a ser del tipo distribución normal, sería recomendable realizar una normalización del tipo *zscore*. Por el contrario, si esta distribución tiende a ser del tipo uniforme entonces se optará llevar las variables a un rango 0-1 [42] [44] [45].

2.5.1.3 Selección de características para predictores

Consiste en la selección de variables que tienen mayor influencia en la respuesta del sistema. Esta puede llevarse a cabo mediante una serie de metodologías, donde las más comúnmente utilizadas corresponden a métodos de filtrado, los cuales son aplicados antes del entrenamiento del modelo. Por su parte, estas técnicas están basadas en propiedades estadísticas (media, mediana, desviación estándar, etc) de los predictores y su relación con la variable respuesta [44] [41] [45]. Algunos de las técnicas de filtrado son:

- **Correlación**: es una medida de la relación lineal que existen entre predictores y respuesta, esta permite descartar las variables débilmente relacionadas. Para el cálculo de la correlación es comúnmente utilizado el coeficiente de Pearson, sin embargo, para evaluar relaciones no lineales de tipo monótonas es posible utilizar otros coeficientes como el de Spearman o Kendall.
- **Test estadísticos**: la idea principal detrás de este tipo de prueba consiste en la independencia de dos características que se distribuyen de manera particular cuando estas se encuentran juntas. Para esto se calcula la probabilidad (*p-value*) de que estas dos características sean independientes al analizar su distribución. Si el *p-value* es menor al nivel de significancia establecido (α) se considera como evidencia suficiente para concluir que las características son dependientes.

2.5.2 Entrenamiento de algoritmos

Una vez procesada la información a utilizar y previo al entrenamiento de los algoritmos, es necesario entender cómo es que estos se clasifican según el tipo de variables que son capaces de predecir. Como se puede ver en la Figura 7 donde se muestra un esquema de los algoritmos de *Machine Learning*, estos se clasifican en primera instancia entre máquinas de aprendizaje no supervisado y supervisado. Este último es el grupo de interés para el presente trabajo, el cual busca entrenar un modelo basado

tanto en variables de entrada como en la variable respuesta. En segunda instancia, podemos ver que hay algoritmos de aprendizaje supervisado de tipo regresión y clasificación, el primero de estos es el que se utiliza para la predicción de variables de tipo continua como es el caso de una distribución granulométrica, por lo que el presente trabajo se centró en los algoritmos que se desprenden a partir de esa subclasificación [42] [46].

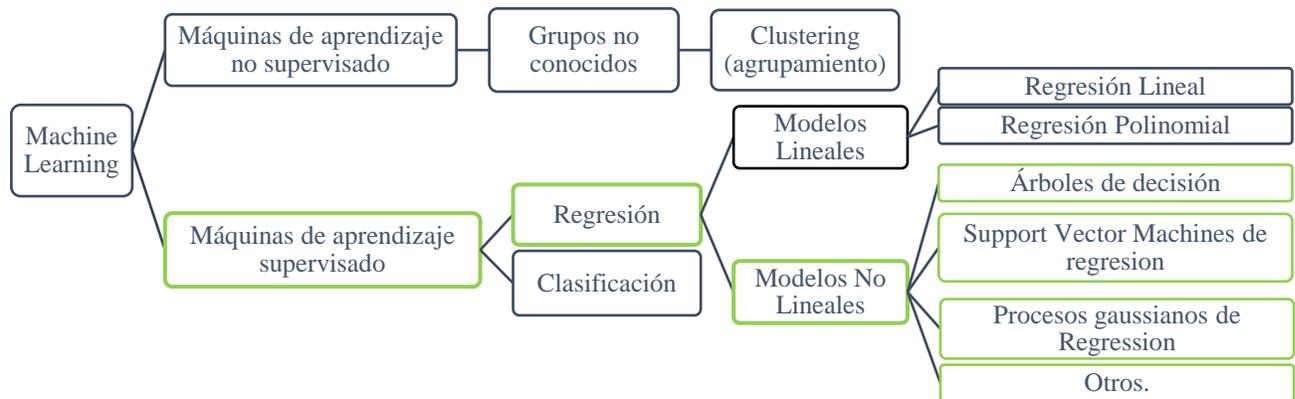


Figura 7: Esquema de algoritmos de Machine Learning [42]

A continuación, en la Figura 8 se muestra una captura de lo que es la interfaz del *Regression Learner*, la cual es la aplicación del software MATLAB que facilitará la posibilidad de entrenar y comprar en primera instancia los modelos predictivos. En la Figura 8 se muestra detalladamente el orden que se debe seguir para comenzar a utilizar el programa donde, en primer lugar, es necesario seleccionar la base de datos a utilizar, en segundo lugar, es preciso escoger la variable respuesta, en tercer lugar, se definen los predictores o variables predictoras que son las variables que entregarán la información para entrenar el modelo, y finalmente, se selecciona el método de validación, esta puede ser de tipo cruzada o subdividiendo la base de datos para entrenamiento y validación. Una vez definido los parámetros anteriores se procede a iniciar la sesión de entrenamiento [41].

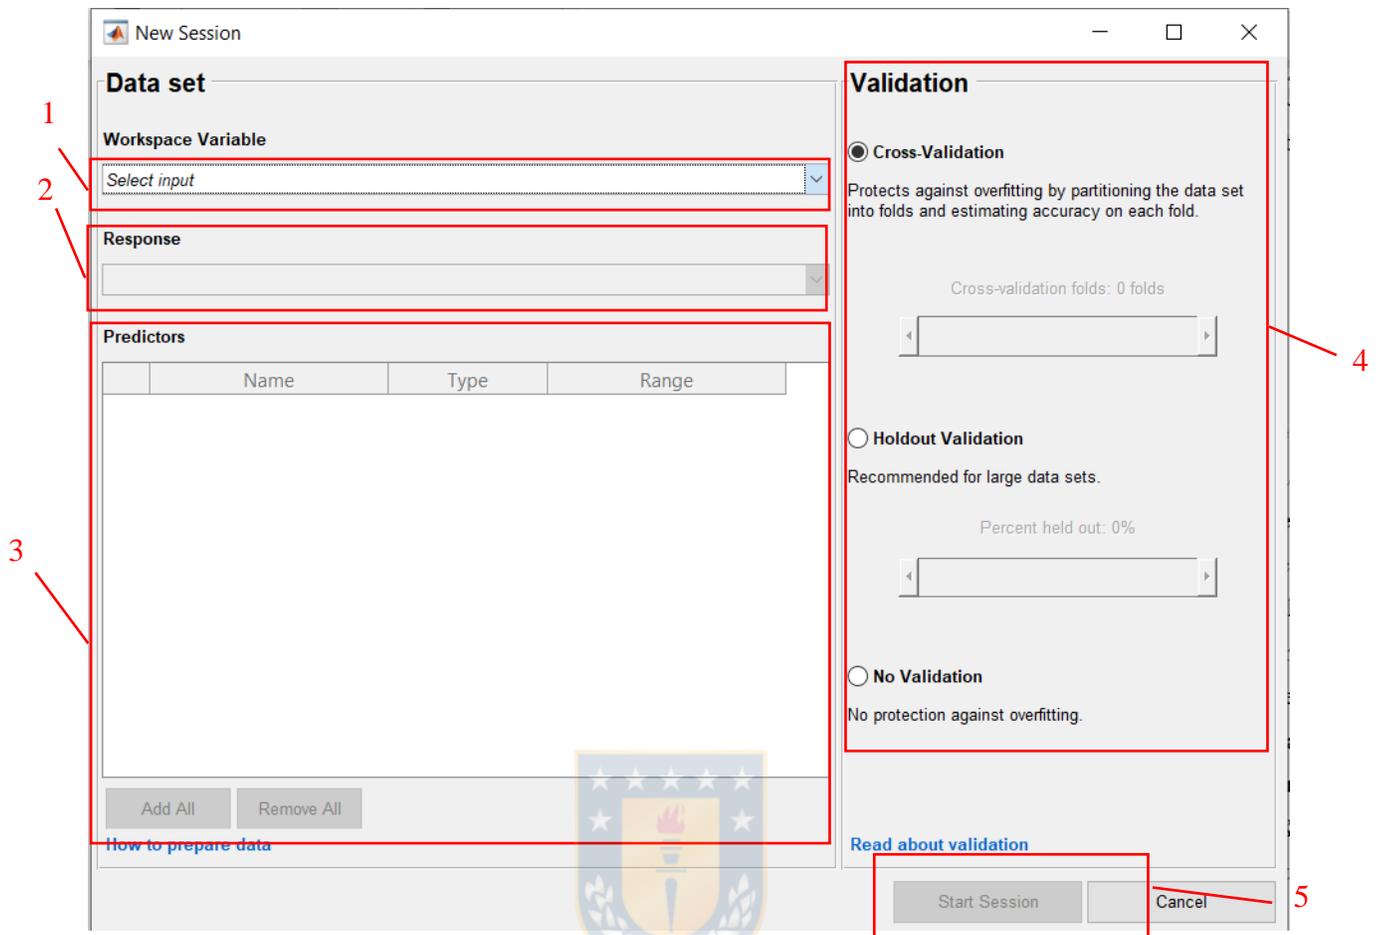


Figura 8: Interfaz de configuración del Regression Learner [41]

2.5.3 Modelos de Regresión

A continuación, se presenta una breve descripción de algunos de los algoritmos disponibles para su entrenamiento en el *Regression Learner* [41] [44].

- **SVM:**

Las máquinas de soporte vectorial o Support Vector Machine son una herramienta tanto de clasificación como de regresión. Para esta última tarea, se considera una técnica no paramétrica, puesto a que mediante una función Kernel, es posible llevar los datos a un hiperplano que permita encontrar una función $f(x)$ que se desvíe de la respuesta por un valor no mayor a ϵ para cada punto x_i , y que al mismo tiempo esta sea lo más lineal posible según la forma del hiperplano adoptada. El conjunto de puntos $X = \{x_1, x_2, \dots, x_n\}$ en base a los que se establece la función $f(x)$ se denominan vectores de soporte.

- **Árboles de Regresión**

Los árboles de regresión consisten en una secuencia de condiciones binarias que clasifican y permiten regresiones no lineales que presentan generalmente un mejor desempeño para problemas donde no existen relaciones definidas entre los predictores y las variables respuesta.

- **Regresiones con Procesos Gaussianos**

Los modelos de regresión del proceso gaussiano (GPR) son modelos probabilísticos no paramétricos basados en una función específica de distribución para predecir observaciones, los valores observados se obtienen a partir de una distribución de probabilidad gaussiana de media 0 y desviación estándar estimada a partir del entrenamiento de los datos.

2.5.4 Validación y medidas de ajuste

La validación es la etapa del proceso donde se decide si el modelo obtenido es el apropiado o no. Para esto existen diversas formas de evaluar la calidad del modelo, para lo cual se utilizan principalmente medidas de ajuste y gráficos de validación [42] [41] [45] [44].

2.5.4.1 Raíz del error cuadrático medio

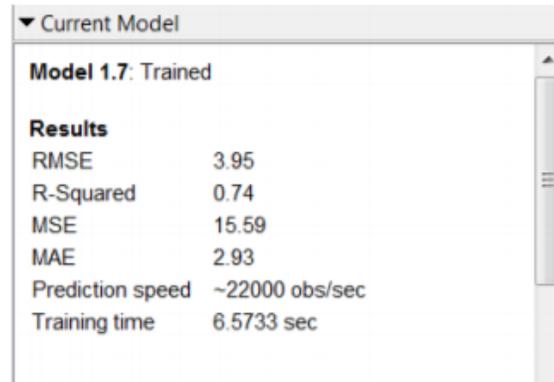
Es una métrica frecuente de las diferencias entre la salida real (y) y estimada (\hat{y}). Su ventaja es que el valor que toma esta variable está en la misma escala que los valores objetivos. (ecuación 2.17)

$$RMSE = \sqrt{\sum \frac{(y - \hat{y})^2}{N}} \quad (2.17)$$

- Donde N corresponde al número total de observaciones de la variable.

2.5.4.2 Coeficiente de determinación

Es una medida de la bondad del ajuste entre dos variables, mientras menor es el valor de R^2 menor será la correlación entre estas variables. La bondad de ajuste siempre es menor que 1 y usualmente mayor que 0 y cuando esta es menor a 0, significa que el modelo comparado es peor que el modelo entrenado



Current Model	
Model 1.7: Trained	
Results	
RMSE	3.95
R-Squared	0.74
MSE	15.59
MAE	2.93
Prediction speed	~22000 obs/sec
Training time	6.5733 sec

Figura 9: Estadísticas de un modelo entrenado en el Regression Learner [41]

2.5.4.3 Gráficos de Validación

Además de las métricas comentadas anteriormente otra forma práctica de ver el desempeño de un modelo entrenado son las gráficas “Real vs. Estimado”, estas permiten entender qué tan bien el modelo de regresión predice, ya que pone en un eje los valores de la variable estimada con el modelo entrenado y en el otro eje, los valores originales de la variable respuesta. Cuando el modelo entregado genera una buena estimación, la gráfica muestra los puntos agrupados en una diagonal ascendente [41].

2.6 GESTIÓN DE LA FRAGMENTACIÓN EN LA INDUSTRIA

La fragmentación es uno de los principales objetivos de la perforación y tronadura, al verse esta como el objetivo de un proceso, también es posible analizar como este puede verse optimizado mediante la implementación de un sistema de gestión de calidad. Desde esta perspectiva la ISO 9001 (2015) propone la aplicación del ciclo PHVA enfocado a procesos y una postura basada en los riesgos para organizar y gestionar el uso de recursos, en consecuencia, del cumplimiento de los objetivos [5].

2.6.1 Ciclo Planifica-Hacer-Verifica-Actuar enfocado a la perforación y tronadura

El ciclo Planificar-Hacer-Verificar-Actuar (PHVA) permite a una organización asegurarse de que sus procesos cuenten con recursos y, se gestionen adecuadamente en post de alcanzar sus objetivos con altos estándares de calidad. Esto, complementado al pensamiento basado en riesgos, permite a una organización determinar los factores que podrían causar que sus procesos y, los sistemas de gestión de calidad (SGC), se desvíen de los resultados planificados, puesto que pone sobre la mesa los controles preventivos para minimizar los efectos negativos y maximizar el uso de las oportunidades a medida que estas surjan dentro del proceso y sus etapas [47].

Si se analiza la perforación y tronadura según el ciclo de Deming (PHVA) es posible identificar todos los elementos del ciclo reflejados en las etapas de la operación. Esto se puede observar de manera más clara en la Figura 10, donde en el eje central se agrupan los subprocesos de la perforación y tronadura según las etapas del ciclo de Deming. A la izquierda de este eje, se encuentran las entradas para el SGC y a la derecha, se encuentran los productos de cada etapa donde se registran los mecanismos de control y el cumplimiento o no de las tareas y objetivos.

2.6.1.1 Planificar

En la etapa de “*Planificar*” se organizan las acciones que permitan asegurar que el proceso sea capaz de lograr los resultados previstos, en función de los requisitos del cliente, que en este caso sería la planta de procesamiento. Lo anterior mediante la generación de diseños de malla de perforación, diseño de secuencias de tronadura y selección de un modelo predictivo para estimar la fragmentación obtenida como resultado del proceso. A su vez, la planificación de acciones buscará aumentar los efectos deseables, disminuir o prevenir los efectos no deseados (vibraciones, sobre tamaños, daño al macizo rocoso, etc.) y lograr una mejora general del proceso (excelencia operacional) mediante la planificación y evaluación de la eficacia de estas acciones [5].

La entrada principal para esta etapa, desde un punto de vista más práctico, será la información utilizada para generar el *caso base* a partir de antecedentes geológicos, geotécnicos, topográficos e hidrológicos. El caso base corresponde a un lineamiento general que se hace para tener claridad respecto al estado de la roca y del macizo. El caso base y la información que este provee del estado de la roca es lo que dará paso a realizar la calibración de un modelo empírico, el cual permitirá estimar los resultados en términos granulométricos de diferentes diseños de malla y así definir el que presente resultados más cercanos a los objetivos de la operación [48] [49].

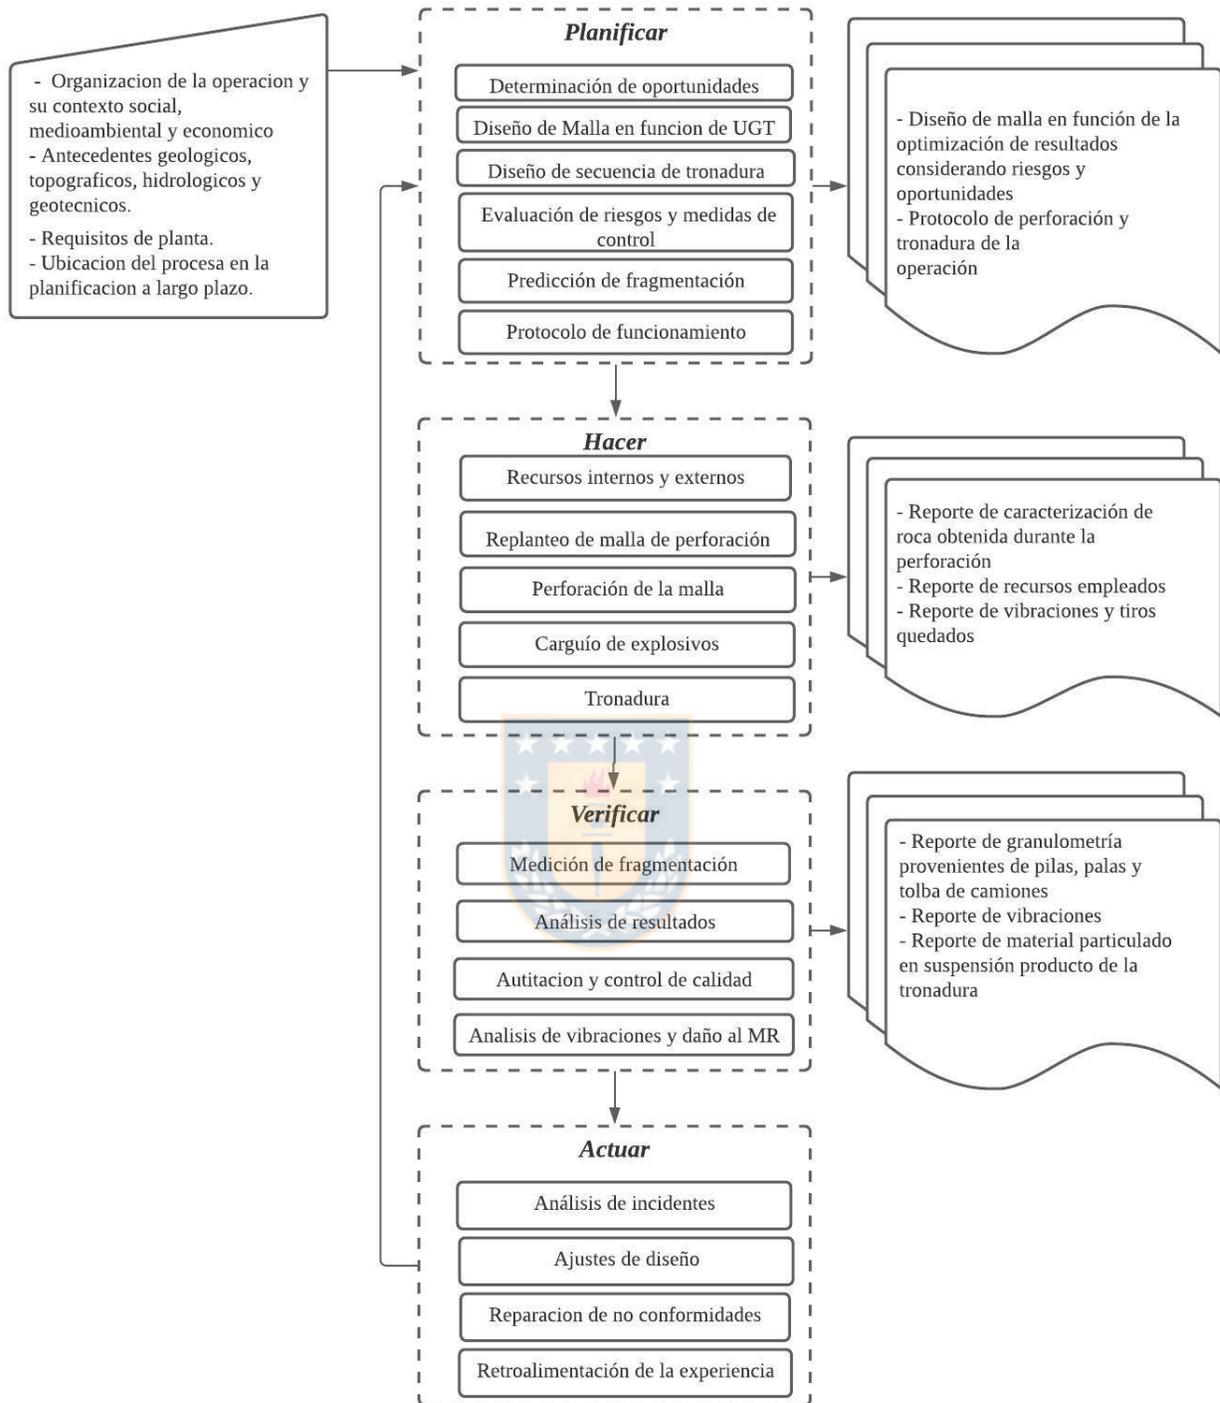


Figura 10: Ciclo PHAV enfocado a la perforación y tronadura

2.6.1.2 Hacer

Una vez finalizada la planificación se procede a la etapa del “Hacer”, donde en primera instancia, se consideran las capacidades y limitaciones de los recursos internos existentes (maquinaria, personal, infraestructura, suministros, sistemas de seguimiento y control, etc.) y luego se evalúa la necesidad de recurrir a proveedores externos para suplir dichas necesidades (EPE, auditorías, calibración sistemas de medición, etc.). Lo anterior es necesario para posteriormente dar paso a la ejecución de las actividades planeadas que se pueden ver en la Figura 10, durante las cuales se desarrolla un exhaustivo control operacional para asegurar el cumplimiento de los estándares del proceso, de los servicios suministrados por agentes externos e internos y de los productos de la etapa. Sin embargo, a pesar de los protocolos y responsables asignados para el control operacional que se desarrolla durante esta etapa, se puede decir que no existe una constancia de cómo esta información ha sido o no incorporada en la etapa donde se realizan acciones correctivas sobre las no conformidades del proceso [1] [50] [5].

2.6.1.3 Verificar

Una vez definidos los elementos del proceso que estarán bajo seguimiento y medición, es necesario definir qué métodos se utilizarán para ello, en qué momento estos serán verificados y cuándo se realizará la evaluación de resultados. En lo que respecta a la fragmentación producto de la tronadura, el principal método de verificación que se utiliza actualmente en la industria es la medición de granulometría mediante el procesamiento digital de imágenes a partir de fotografías capturadas en la pala durante el proceso de carga, en la tolba de camiones durante la descarga y/o en correas durante su transporte. Una vez realizada la medición es necesario llevar a cabo un análisis de los resultados para estimar el grado de satisfacción con el desempeño y la efectividad del proceso. En base a esto es que se desarrollan auditorías internas para saber si el proceso se implementa y mantiene de manera eficaz tanto en términos de fragmentación como para los efectos de las vibraciones sobre el macizo rocoso [5] [51] [6].

2.6.1.4 Actuar

Finalmente, en la etapa de “Actuar” es donde se toman acciones en función de aprovechar las oportunidades de mejora y cumplir con los requisitos de la planta, paralelo a esto se deben corregir, prevenir o reducir los efectos no deseados del proceso (granulometría poco uniforme, la necesidad de tronadura secundaria, presencia de tiros quedados, etc.). En lo que respecta a la fragmentación, esta etapa es la que da paso a la generación de nuevos diseños de malla, ajustes en las secuencias de tronadura y calibración del modelo empírico utilizado para predecir la fragmentación. Una vez

definidas las acciones correctivas el ciclo vuelve a comenzar incorporando estas a la planificación [5] [1] [50].

2.6.2 Factores que podrían condicionar la estimación de fragmentación

Cuando los resultados de fragmentación no cumplen con los estándares esperados, se desencadena una serie de interrogantes para dilucidar en qué parte del proceso gatilla la división entre lo estimado y lo real. ¿Se interpretó correctamente la información? ¿Se calibró correctamente el modelo? Son sólo un ejemplo de las interrogantes inmediatas que surgen frente a un desempeño deficiente de la tronadura en términos de fragmentación. Generalmente, gracias a los estándares operacionales que maneja la industria minera y a las constantes mejoras en el control del desarrollo de operaciones como, por ejemplo, la incorporación de sistemas de GPS en perforadoras para mejorar la precisión conforme al diseño, la implementación de detonadores electrónicos para disminuir la dispersión en la detonación y prevenir la existencia de tiros quedados, la desviación estándar de detonación y las consecuencias que esto puede tener, etc. Se puede decir, que es bastante poco probable que se produzca debido a una falla operacional. En base a lo anterior se desprende que la falta de exactitud de la estimación se debe principalmente a tres factores: la dudosa representatividad de la información utilizada para la generación del caso base, un nulo procesamiento de la información y/o la utilización de un modelo empírico inadecuado [1].

2.6.2.1 Representatividad de la información

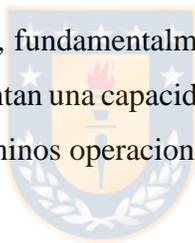
Es comprensible que las condiciones de roca cambien a medida que la operación avanza en cuanto a la profundidad del rajo, por lo que es entendible que los antecedentes utilizados para la generación del caso base inicialmente también cambien. Simultáneamente, es posible apreciar que con el pasar de los años y considerando las innovaciones tecnológicas que van presentando las diferentes empresas ligadas al rubro, se le otorga cada vez mayor importancia a una correcta caracterización tanto de la roca como del macizo rocoso en el banco sobre el cual se está trabajando. Esto como consecuencia de la influencia que esta información tiene en los modelos empíricos disponibles y más utilizados por la industria, lo que queda en evidencia con el desarrollo de sistemas de medición durante la perforación (MWD), puesto que acceden a la captura y almacenamiento de estos antecedentes durante la perforación, por lo tanto admite tener mayor claridad del estado de la roca, sus estructuras y discontinuidades, en otras palabras, permiten medir “a pulso” cómo es que el macizo va evolucionando. Sin embargo, este tipo de avances tecnológicos no se encuentran presentes o no son debidamente aprovechados en todas las operaciones [52] [1].

2.6.2.2 *Procesamiento de la información*

Al analizar la forma en la que se procesa la información, nos encontramos con el desarrollo de sistemas integrados de información dentro de una operación minera, es decir: captación, almacenamiento y gestión de datos pertenecientes a todas las operaciones unitarias. Lo anterior está orientado al valor de la información, por ende, el hecho de tener acceso a más y mejores datos de una mina, permite procesar y comprender el negocio, optimizando la toma de decisiones. Esto se puede ver evidenciado en el desarrollo de sistemas integrados como BlastIQ patentado por Orica, demostrando la clara intención de una empresa por estar presente en cada etapa de una operación minera, ofreciendo los beneficios que esto tiene. Otros ejemplos de esta intención se aprecian en el desarrollo de software SCADA integrados por parte de Maptek, Timining, JKTech, entre otros [48].

2.6.2.3 *Modelos predictivos para la estimación de fragmentación*

A lo largo de la historia se han desarrollado una serie de modelos que tienen por finalidad modelar el comportamiento de la distribución granulométrica en base a parámetros de diseño, caracterización de roca, propiedades del explosivo y distribución correcta de la energía. Sin embargo, la factibilidad de las simulaciones de fragmentación depende, fundamentalmente, de la habilidad de los modelos para reproducir procesos físicos, los cuales presentan una capacidad predictiva menor a la deseada a cambio de una parametrización más práctica en términos operacionales [2] [3] [31] [52].



3 DESARROLLO

3.1 CASO DE APLICACIÓN

La base de datos utilizada para el presente trabajo fue proporcionada por el área de Perforación y Tronadura de Minera Los Pelambres (MLP), un complejo minero metalúrgico perteneciente al Grupo Minero Antofagasta Minerals S.A. (AMSA), la cual se posiciona como la quinta empresa con mayor producción de cobre a nivel nacional. El complejo minero metalúrgico se encuentra subdividido en tres sectores operacionales: mina a cielo abierto, planta concentradora y el puerto de Punta Chungo. Los datos provienen de las tronaduras realizadas en la mina a cielo abierto dedicada a la explotación de un yacimiento masivo del tipo pórfido de cobre y molibdeno de edad Miocénica, ubicado actualmente a 45.0 [km] al este de la ciudad de Salamanca, en la IV región de Coquimbo, y solo a 1.0 [km] de la frontera geográfica entre Chile y Argentina.



Figura 11: Ubicación del complejo minero Los Pelambres (Bonzi, 2016)

3.1.1 Unidades Geotécnicas en Mina Los Pelambres

En la mina a cielo abierto se produce la agrupación de zonas que comparten una serie de características litológicas, mineralógicas y mecánicas en común denominadas Unidades Geotécnicas (UGT) clasificadas según su ubicación con respecto al techo de anhidrita que representa la división geológica entre la mineralización supérgena e hipógena. A continuación, se muestra una tabla que resume algunas de las propiedades de las UGT las cuales fueron anexadas de manera extraoficial al presente trabajo.

Tabla 1: Propiedades de unidades geotécnicas en Mina Los Pelambres [53]

UGT	Litología	ρ [t/m ³]	Ei ¹ [GPa]	UCS [MPa]	Ti ² [MPa]	RMR promedio	RQD promedio [%]	GSI	ACB ³ [°]	H ⁴ [m]	AB ⁵ [m]	Te ⁶ [ms]	Tf ⁷ [ms]
1	Primario con anhidrita	2.66	61	135	6	82	98	77	80	30	16.5	5	95
2	Primario sin anhidrita	2.63	62	106	7	69	84	64	80	30	16.5	5	95
3	Secundario	2.53	36	90	5	61	81	56	80	30	18.1	5	84
4	Andesita oeste inferior	2.82	67	132	8	77	95	72	-	-	-	7	84
5	Andesita oeste intermedia	2.79	53	95	5	43	27	39	70	15	7.9	7	84
6	Andesita oeste superior	2.84	42	76	5	54	51	49	80	30	18.1	7	84
7	Andesita este inferior	2.86	55	140	5	82	100	77	-	-	-	5	84
8	Andesita este superior	2.84	34	90	4	50	56	45	-	-	-	7	84
9	Lixiviado	2.56	32	58	3	57	77	52	80	30	18.1	7	110
10	Lixiviado Sericita	2.66	28	52	2	42	41	37	80	30	18.1	7	110
11	PQF secundario	2.6	29	163	11	64	82	59	80	30	18.1	7	110
12	Intrusivos menores	2.62	32	66	4	62	83	52	80	30	18.1	5	84

¹ Módulo de elasticidad

² Tracción indirecta

³ Ángulo de cara de banco

⁴ Altura de banco

⁵ Ancho de berma

⁶ Tiempo entre pozos

⁷ Tiempo entre filas

3.2 EXPLORACIÓN DE DATOS

3.2.1 Base de datos

El primer paso previo al trabajo con la información es importar la base de datos y revisar qué variables contiene. Para esto se generó una función en MATLAB que incorporó la base de datos original disponible en un archivo “.csv” con 100 tronaduras, posteriormente se revisaron las variables que esta contenía y se compararon con las variables que consideran los modelos empíricos más utilizados para la estimación de fragmentación. Esto se puede ver resumido en la Tabla 2 donde las variables se encuentran agrupadas en cuatro categorías generales. La información que se encuentra destacada con gris en la columna “Base de Datos” corresponde a información anexada de manera extraoficial y promediada. Las variables, en la misma columna, destacadas en azul corresponden a datos de catálogo del proveedor de explosivos. En consideración de lo anterior, es posible ver que la cantidad de parámetros requeridos por los modelos es levemente superior a la cantidad que dispone la base de datos original, lo que condicionará la estimación de fragmentación debido a que será necesario asumir ciertos valores para completar la estimación con los modelos Kuz-Ram y KCO. El código utilizado para incorporar la información de UGT se encuentra en el Anexo A.

Tabla 2: Comparación de información entre modelos y base de datos

MODELOS		CZM	KR	KCO	Base de Datos
PROPIEDAD DE ROCA Y ESTRUCTURAS	DISCONTINUIDADES		✓	✓	✓
	PRESENCIA DE AGUA				
	CALIDAD DEL MACIZO		✓	✓	
	DENSIDAD DE LA ROCA	✓	✓	✓	✓
	TAMAÑO MAXIMO DE BLOQUE			✓	
	ELASTICIDAD DE LA ROCA	✓	✓	✓	✓
	RESISTENCIA A LA COMPRESION	✓	✓	✓	✓
	VELOCIDAD DE PROPAGACION DE ONDA	✓	✓	✓	
	VELOCIDAD CRITICA DE PARTICULA				
	RESISTENCIA A LA TENSION	✓			✓
DISEÑO DE TRONADURA	BURDEN	✓	✓	✓	✓
	ESPACIAMIENTO	✓	✓	✓	✓
	DIAMETRO DE POZO	✓	✓	✓	✓
	ALTURA DE BANCO	✓	✓	✓	✓
	DISPERSION DE PERFORACION (PATRON)				

	DISPERSION DE PERFORACION (LARGO POZO)	✓	✓	✓	
	NUMERO DE POZOS POR FILA				
	NUMERO DE FILAS				
	TAMAÑO DE BLOQUE TRONADO				
EFECTO DEL TIEMPO	TIEMPO ENTRE POZOS	✓	✓	✓	✓
	TIEMPO ENTRE FILAS				✓
	TIEMPO DE FONDO				
	TIEMPO SUPERFICIAL				
	DISPERSION DEL DETONADOR	✓	✓	✓	
DESEMPEÑO DE LA DETONACION	DENSIDAD EXPLOSIVO	✓			✓
	CARGAS MULTIPLES		✓	✓	
	KILOS DE EXPLOSIVO	✓	✓	✓	
	CARGAS DESACOPLADAS	✓	✓	✓	
	FACTOR DE CARGA	✓	✓	✓	✓
	VOD	✓			✓
	EQUIVALENCIA ENTRE EXPLOSIVOS	✓	✓	✓	✓
	PRESION DE DETONACION	✓	✓	✓	✓

(Elaboración propia)

Una vez completada la base de datos añadiendo la caracterización de UGT existente, se procede a almacenar la información de la base de datos en vectores para su posterior operación.

```

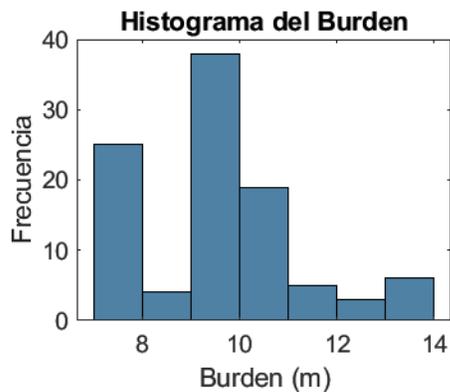
filas = height(datos);
[B,S] = burdenandspacing(datos.BxS,filas); %Extrayendo burden y espaciamiento
[d,ro] = diam2mili(datos.Dimetro,filas); %Diámetro de pozo en milímetros.
[vod,rhoe,pdet,rws] = explosiveparameters(datos.TipoExplosivo,filas); %explosivos
[PF] = powderfactor(datos.Fc,rho,filas); %Factor de Carga
[Vt,Q] = explosivequantity(B,S,H,PF,filas); %Cantidad de Explosivo

```

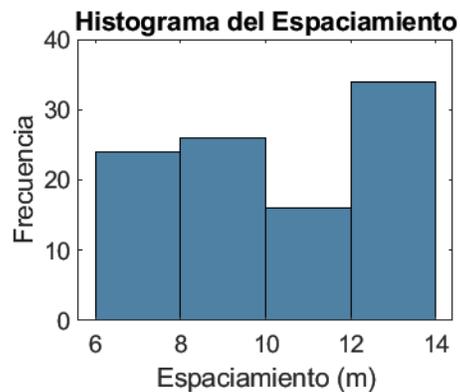
Finalmente, se almacenan los vectores anteriormente creados para el trabajo con esta base de datos de manera ordenada en la tabla “datos2”.

3.2.2 Comportamiento de las variables en la base de datos

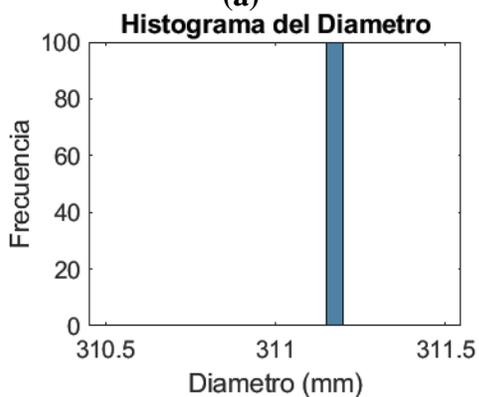
La primera parte del procesamiento de la información es entender cómo es que las variables se comportan a lo largo de la base de datos. Esto se puede revisar mediante los histogramas de cada variable como se muestra a continuación.



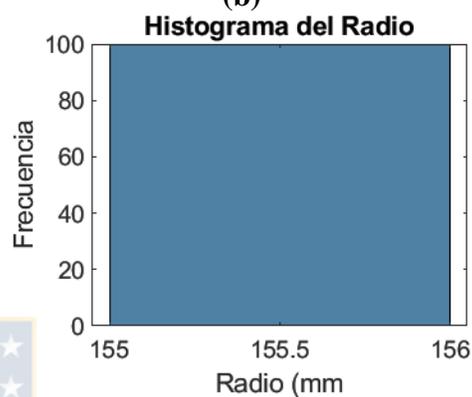
(a)



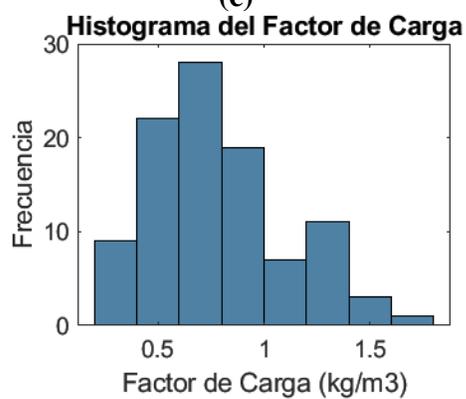
(b)



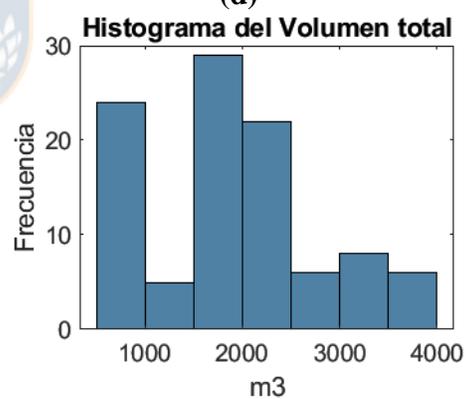
(c)



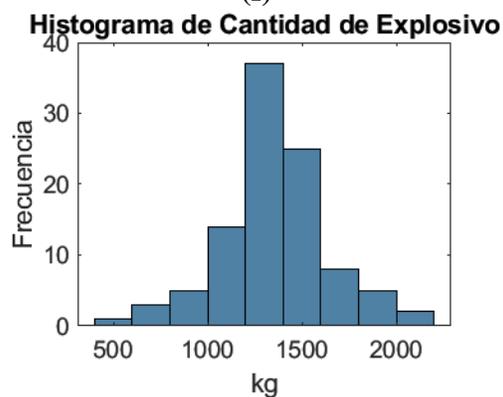
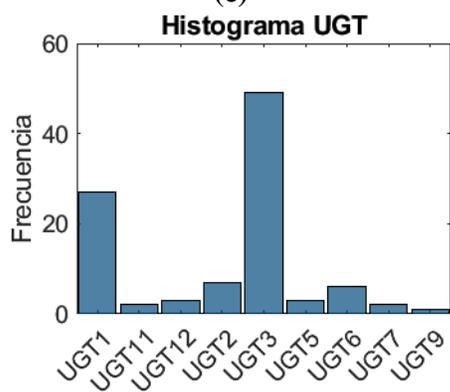
(d)



(e)



(f)



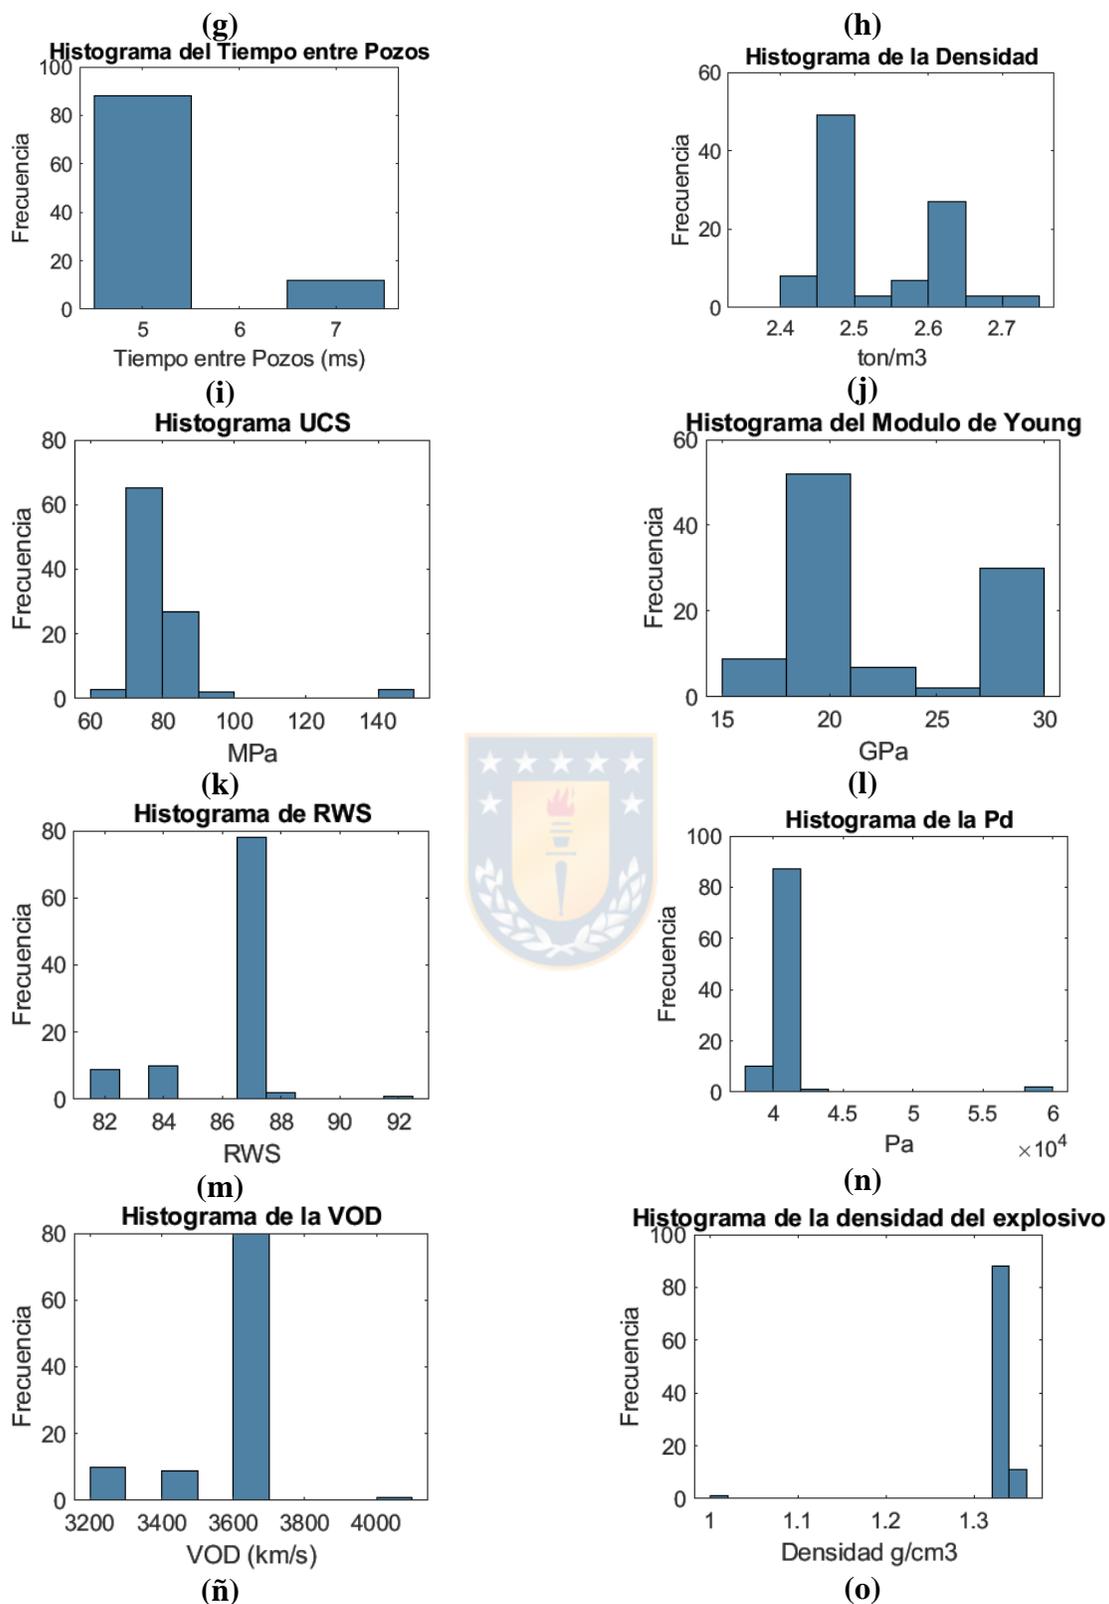


Figura 12: Histogramas de las variables presentes en "datos2"

(Elaboración propia)

En lo que respecta a las variables de diseño como son burden, espaciamiento, diámetro y radio de pozos, se puede decir que las dos últimas se muestran constantes a lo largo de la base de datos. Al presentar varianza nula, serán descartados como predictores al momento de realizar el entrenamiento de los algoritmos. Para el caso de las variables burden y espaciamiento se puede apreciar que estas si presentan variabilidad, sin embargo, el caso de la distribución de espaciamiento se muestra de tipo más uniforme en comparación a la de burden, razón por la cual esta última será predilecta al momento de estudiar la influencia de las variables de diseño en la estimación de fragmentación utilizando algoritmos de ML.

Para el caso de las Figuras 13.e, 13.f y 13.g se puede apreciar una distribución relativamente normal por lo que, al igual que la variable burden, serán relevantes a la hora del entrenamiento de los algoritmos. Por su parte, la variable cantidad de explosivo y volumen total son variables que son producto de una transformación de la variable Factor de Carga, lo que hace que estas últimas sean objeto de análisis en la estimación. En lo que respecta a tiempo entre pozos esta se encasilla en solamente dos valores, por lo que será necesario estudiar su comportamiento como predictor.

Con relación a las variables UCS, Modulo de Young y Densidad, se puede ver en las Figuras 13.j, 13.k y 13.l que la primera de estas presenta una menor variabilidad. Pese a ser consideradas como “variables claves” debido a que caracterizan la roca, es necesario tener como antecedentes el origen de esta información anexada lo que puede afectar la representatividad de esta información. De igual manera será necesario estudiar la relación de estas con la variable respuesta, en este caso, el P50.

En lo relacionado a las variables que se desprenden del explosivo (RWS, VOD, densidad del explosivo y Pd) estas muestran histogramas bastante similares entre si con varianzas bajas similares a lo que ocurre con el diámetro y radio de tiro. Esto tendrá como consecuencia un bajo interés en su análisis por separado como predictores puesto que al no aportar información extra que condicione la estimación.

3.2.3 Procesamiento de datos

3.2.3.1 Datos Atípicos y faltantes

En vista del comportamiento que tienen las variables a lo largo de la base de datos, visto en la Figura 12 y una revisión de las estadísticas, se puede ver que no se presentan datos atípicos ni faltantes en las variables, por lo que no será necesario realizar este procedimiento para el presente caso.

3.2.3.2 Normalización de datos

La normalización es un proceso mediante el cual se estandariza el rango entre el que se mueven los valores de una variable, esto permite que al trabajar con un conjunto de predictores con magnitudes diversas esto no altere su ponderación como predictor para el entrenamiento de los algoritmos. Para esto lo que se realizó fue la creación de una base de datos especial para ser normalizada, la cual no incluye ni el nombre de la tronadura ni la UGT por no ser variables de tipo lógica ni numérica. A continuación, se muestra el código utilizado.

```

datos3 = table(datos2.Burden,datos2.Espaciamiento,datos2.("Tiempo entre
Pozos"),datos2.VOD,...
  datos2.("Densidad Explosivo"),datos2.("Presion de
Detonacion"),datos2.RWS,datos2.("Powder Factor"),...
  datos2.("Volumen Total"),datos2.("Cantidad de Explosivo"),datos2.("Densidad
ton/m3"),datos2.("UCS MPa"),...
  datos2.E_GPa,datos2.P10,datos2.P20,datos2.P30,...
datos2.P40,datos2.P50,datos2.P60,datos2.P70,datos2.P80,datos2.P90,datos2.P100);
datos3.Properties.VariableNames = ["Burden","Espaciamiento","Tiempo entre Pozos",
"VOD",...
  "Densidad Explosivo","Presion de Detonacion","RWS","Powder Factor",...
  "Volumen Total","Cantidad de Explosivo","Densidad ton/m3","UCS MPa",...
  "E_GPa","P10","P20","P30","P40","P50","P60","P70","P80","P90","P100"];

```

Almacenamiento de media, desviación estándar, máximo y mínimo para posterior desnormalización.

```

P50mean = mean(datos2.P50);
P50std = std(datos2.P50);
P50min = min(datos2.P50);
P50max = max(datos2.P50);
zscoredatos3 = normalize(datos3);
rangedatos3 = normalize(datos3,"range");

```

3.2.3.3 Selección de características

En primera instancia se analizaron las correlaciones que existen entre las variables predictoras y la variable respuesta (P50). Teniendo como antecedente que en los modelos empíricos, las relaciones son en su mayoría de tipo no lineal, por lo que se realizó el cálculo de los coeficientes de Kendall y Spearman que se pueden ver a continuación en la Tabla 3. Sin embargo, no se apreció una notable diferencia en las correlaciones por lo que adicionalmente se visualizaron los gráficos de correlación (Anexo B) para estudiar el comportamiento de las variables donde se pudo apreciar que efectivamente no existe ninguna tendencia clara en la mayoría de las variables a excepción de algunas que presentaban tendencias arqueadas que se podrían interpretar como no monótonas. A partir de esto se presume que los coeficientes de correlación no son suficientes para concluir respecto a cómo es que las variables influyen en la estimación del P50.

Tabla 3: Correlaciones entre variables predictoras y P50

Variable	Pearson	Kendall	Spearman
B	-0.2669	-0.2338	-0.3069
S	-0.3544	-0.2771	-0.3666
Te	-0.0806	-0.0444	-0.0538
VOD	-0.6138	-0.4569	-0.5596
Rho_e	0.0728	0.1752	0.2128
Pd	-0.2371	-0.3591	0.4361
RWS	-0.5053	-0.4331	-0.5484
PF	0.3378	0.1431	0.2199
Vt	-0.2759	-0.2673	-0.3578
Q	-0.2042	-0.1471	-0.2141
Rho	0.3906	0.3367	0.4548
UCS	0.1026	0.3455	0.4550
E	0.5151	0.4202	0.5263
P50	1.0000	1.0000	1.0000

En base a lo anterior es que se decidió realizar las pruebas estadísticas de χ^2 para las variables de interés estratégico en función de los antecedentes teóricos. Para esto se asumió un nivel de significancia de 0.05. Según lo que se aprecia en la Tabla 4 los valores del p-value superan al nivel de significancia en todas las variables, lo que se puede considerar como evidencia suficiente para concluir

que las variables en cuestión son independientes de la variable P50, por lo que al momento de entrenar los algoritmos estas se verán postergadas como predictores.

Tabla 4: P-value para variables con comportamiento irregular

Variable	B	Te	E	VOD	Rho	Rho_e
P-value	0.3311	0.6912	0.4965	0.2857	0.1913	0.7520

3.3 ESTIMACIÓN DE FRAGMENTACIÓN UTILIZANDO MODELOS EMPÍRICOS

En lo que respecta al proceso de estimación, se decidió realizar la comparación de la estimación del tamaño medio de la distribución (P50) debido a que es un parámetro en común entre los modelos y corresponde a una de las variables existente en la base de datos. Para esto se ingresaron las ecuaciones dentro de un ciclo iterativo que fue calculando el tamaño medio para cada observación utilizando el modelo KR y KCO. Tras obtener los resultados se procedió a calcular los residuos y métricas de ajuste los cuales se analizan con mayor detalle en el capítulo 4.

3.3.1 Kuz-Ram

```

for i =1:filas
    datos2.Tmax(i) = 15.6*datos2.Burden(i)/Vp;
    datos2.A_t(i) = 0.06*(datos2.("Tiempo entre Pozos")(i)/datos2.Tmax(i))^3 -
0.13*(datos2.("Tiempo entre Pozos")(i)/datos2.Tmax(i))^2 ...
    -1.58*(datos2.("Tiempo entre Pozos")(i)/datos2.Tmax(i)) +2.1;
    datos2.X50kr(i) = datos2.A_t(i)*A*datos2.("Powder
Factor")(i)^(0.8)*datos2.("Cantidad de
Explosivo")(i)^(1/6)*(115/datos2.RWS(i))^(19/20);
    datos2.n(i) = (2.2 -14*datos2.Burden(i)/datos2.("Diametro (mm)")(i)) *
sqrt(0.5*(1 + datos2.Espaciamiento(i)/datos2.Burden(i))) ...
    * (1 -W/datos2.Burden(i))*0.1*L/H;
end
yorig = datos.P50;
Y_eKR = datos2.X50kr;
KR_met = rMetrics(yorig,Y_eKR)

```

3.3.2 KCO

```

for i =1:filas
    datos2.Xmax(i) = datos2.P100(i);

```

```

cosa = 1+1/datos2.n(i);
datos2.gn(i) = (log(2)^(1/datos2.n(i)))/gamma(cosa);
datos2.X50kco(i) = datos2.X50kr(i)*datos2.gn(i);
datos2.b(i) = 2*log(2)*log(datos2.Xmax(i)/datos2.X50kr(i))*datos2.n(i);
end

Y_eKCO = datos2.X50kco;
KCO_met = rMetrics(yorig,Y_eKCO)

```

3.4 ESTIMACIÓN DE FRAGMENTACIÓN CON ALGORITMOS DE MÁQUINAS DE APRENDIZAJE

3.4.1 Entrenamiento de algoritmos sin normalizar base de datos

Para el entrenamiento de los algoritmos se utiliza la aplicación de MATLAB llamada *Regression Learner* mencionada el capítulo 2.5. Una vez cargada la base de datos e incluidas las variables predictoras (Tabla 5) Tabla 5: Lista de variables y sus abreviaciones se procede a realizar el entrenamiento de los algoritmos disponibles en la aplicación, para lo cual, fue necesario realizar varias iteraciones con la finalidad de evaluar la influencia que tenían las variables en la capacidad predictiva de los modelos entrenados. Dicho proceso se puede ver resumido a continuación en la Tabla 6: Bitácora de entrenamiento de algoritmos cuyos resultados serán comentados en el Capítulo 4. Una vez que se definieron los mejores 5 modelos, estos son exportados para posteriormente realizar la estimación del P50.

Tabla 5: Lista de variables y sus abreviaciones

Variable	Nomenclatura
Burden	B
Espaciamiento	E
Tiempo entre pozos	Te
Velocidad de detonación	VOD
Relative weigth strenght	RWS
Presión de detonación	Pd
Densidad del explosivo	Rhoe

Powder factor	PF
Cantidad de Explosivo	Q
Densidad de roca	Rho
Volumen total	Vt
Resistencia a la compresión	UCS
Módulo de Young	E

Tabla 6: Bitácora de entrenamiento de algoritmos

Base de Datos	Datos2				
Validación	5folds cross validation				
Predictores	B, S, Te, VOD, RWS, Pd, Rho_e, PF, Q, Rho, UGT, UCS, E, Vt.				
Primera iteración: sin burden					
Algoritmos	F tree	MSVM	Ebag tree	EGPR	CSVM
RMSE	25.59	26.51	26.07	27.67	27.71
R ²	0.39	0.36	0.37	0.29	0.30
Segunda iteración: todos los predictores					
Algoritmos	F tree	MSVM	EBagT	CVSM	EGPR
RMSE	25.59	26.65	27.47	27.84	28.14
R ²	0.39	0.36	0.30	0.30	0.26
Tercera iteración: sin tiempo entre pozos					
Algoritmos	F tree	MSVM	EBagT	CSVM	EGPR
RMSE	25.59	27.78	28.43	28.78	29.06
R ²	0.39	0.3	0.25	0.25	0.21
Cuarta iteración: sin VOD					
Algoritmos	F tree	MSVM	Ebag T	CSVM	EGPR
RMSE	25.59	27.78	28.43	28.78	29.06
R ²	0.39	0.3	0.25	0.25	0.21
Quinta iteración: sin PF					
Algoritmos	F tree	MSVM	CSVM	EBagT	EGPR
RMSE	26.74	27.15	27.71	27.74	28.128
R ²	0.34	0.33	0.30	0.28	0.26
Sexta iteración: sin densidad de roca					
Algoritmos	F tree	MSVM	CSVM	EBagT	EGPR
RMSE	25.59	26.73	27.73	27.96	27.97
R ²	0.39	0.35	0.30	0.27	0.27

Séptima iteración: sin E					
Algoritmo	F tree	MSVM	CSVM	EBagT	EGPR
RMSE	25.21	26.63	27.85	28.02	28.14
R ²	0.41	0.36	0.30	0.27	0.26
Octava iteración: Entrenamiento con algoritmo <i>fine tree</i> probando diferentes combinaciones de predictores					
Predictor	S/E, B	S/E, B, VOD	S/E, B, VOD, P		
RMSE	25.21	25.21	25.21		
R ²	0.41	0.41	0.41		
Novena iteración: solamente Medium SVM restando predictores					
Predictor	S/E, B	S/E, B, Te	S/E, B, Te, VOD	S/E, B, Te, VOD, P	
RMSE	26.46	26.34	27.18	26.995	
R ²	0.37	0.37	0.33	0.34	
Decima iteración: sin E, B y Te					
Algoritmos	F tree	MSVM	EbagT	EGPR	CSVM
RMSE	25.72	26.39	26.83	27.32	27.74
R ²	0.39	0.37	0.33	0.31	0.30

3.4.2 Estimación de fragmentación con base de datos normalizadas

En vista de la variedad en los órdenes de magnitud de las diferentes variables presentes en la base de datos, es que se propuso el entrenamiento de algoritmos utilizando variables normalizadas. Ambas bases de datos fueron utilizadas y se procedieron a entrenar algoritmos siguiendo el mismo procedimiento anterior, agregando y quitando predictores para estudiar cómo es que estos afectaban la capacidad de estimación del modelo. La bitácora de entrenamiento para ambas bases se puede ver resumida a continuación en la Tabla 7 y la Tabla 8. Para este caso fueron exportados los 3 mejores modelos de cada base, con los que posteriormente también se realizó la estimación del P50 y cuyos resultados se puede revisar en el Capítulo 4.

Tabla 7: Bitácora de entrenamiento con base de datos *zscore*

Base de Datos	Zscoredatos3				
Validación	5 folds validation				
Predictores	B, S, Te, VOD, RWS, Pd, Rhoe, PF, Q, Rho, UGT, UCS, E, Vt.				
Comentarios	modelosegpr_zscore, magpr_zscore y ebost_zscore				
Primera iteración	todos predictores				
algoritmos	EBagT	EGPR	MGPR	RGPR	MSVM
RMSE	0.745	0.748	0.763	0.779	0.777
R ²	0.45	0.44	0.42	0.41	0.40

Segunda iteración		sin burden			
algoritmo	EBosT	EGPR	SGPR	RGPR	MSVM
RMSE	0.744	0.751	0.776	0.776	0.778
R ²	0.45	0.44	0.40	0.40	0.40
Tercera iteración		sin tiempo entre pozos			
algoritmos	EBosT	EGPR	MGPR	SGPR	RGPR
RMSE	0.763	0.784	0.793	0.796	0.796
R ²	0.42	0.39	0.37	0.37	0.37
Cuarta iteración		sin VOD			
algoritmos	EBosT	EGPR	RGPR	MGPR	SGPR
RMSE	0.745	0.753	0.765	0.773	0.784
R ²	0.45	0.43	0.42	0.40	0.39
Quinta iteración		sin power factor			
algoritmos	EGPR	EBosT	MGPR	SGPR	RGPR
RMSE	0.748	0.760	0.764	0.769	0.770
R ²	0.44	0.42	0.42	0.41	0.41
Sexta iteración		sin densidad de roca			
algoritmos	EGPR	EBosT	MGPR	RGPR	SGPR
RMSE	0.751	0.755	0.768	0.776	0.777
R ²	0.44	0.43	0.41	0.40	0.40
Séptima iteración		sin E			
algoritmos	EGPR	EBosT	MGPR	SGPR	RGPR
RMSE	0.743	0.747	0.758	0.763	0.763
R ²	0.45	0.44	0.43	0.42	0.42
Octava iteración		sin módulo de E y burden			
algoritmos	EGPR	EBosT			
RMSE	0.746	0.747			
R ²	0.45	0.44			
Novena iteración		sin E, B y VOD			
algoritmos	EGPR	EBosT			
RMSE	0.749	0.747			
R ²	0.44	0.44			

Tabla 8: Bitácora de entrenamiento con base de datos range

Base de datos	rangedatos 3				
Validación	5 folds validation				
Predictores	B, S, Te, VOD, RWS, Pd, Rhoe, PF, Q, Rho, UGT, UCS, E, Vt.				
Primera iteración		todos predictores			
algoritmos	MSVM	SGPR	MGPR	RGPR	EGPR
RMSE	0.119	0.124	0.124	0.124	0.125

R ²	0.43	0.38	0.38	0.38	0.37
Segunda iteración		sin burden			
algoritmo	MSVM	LSVM	EBosT	MGPR	SGPR
RMSE	0.119	0.123	0.123	0.125	0.125
R ²	0.43	0.40	0.39	0.37	0.37
Tercera iteración		sin tiempo entre pozos			
algoritmos	MSVM	EBagT	SGPR	EBosT	RGPR
RMSE	0.122	0.122	0.123	0.125	0.125
R ²	0.41	0.40	0.39	0.37	0.37
Cuarta iteración		sin VOD			
algoritmos	EBosT	MSVM	EBagT	EGPR	Mtree
RMSE	0.127	0.129	0.129	0.131	0.132
R ²	0.35	0.33	0.33	0.31	0.30
Quinta iteración		sin PF			
algoritmos	MSVM	LSVM	EBosT	SGPR	MGPR
RMSE	0.117	0.121	0.121	0.123	0.123
R ²	0.45	0.41	0.41	0.39	0.39
Sexta iteración					
algoritmos	MSVM	MGPR	RGPR	SGPR	LSVM
RMSE	0.118	0.122	0.122	0.122	0.122
R ²	0.44	0.41	0.40	0.40	0.40
Séptima iteración					
algoritmos	MSVM	SGPR	LSVM	RGPR	MGPR
RMSE	0.119	0.122	0.123	0.123	0.123
R ²	0.43	0.40	0.39	0.40	0.39

A continuación, se muestra el código programado para la estimación utilizando los modelos entrenados con bases normalizadas.

Carga de modelos entrenados

```
load('ebost_zscore.mat'); load('mgpr_zscore.mat'); load('egpr_zscore.mat');
load('msvm_range.mat'); load('lsvm_range.mat'); load('ebost_range.mat')
```

Estimación con los modelos

```
y21 = egpr_zscore.predictFcn(zscoredatos3);
y22 = ebost_zscore.predictFcn(zscoredatos3);
y23 = mgpr_zscore.predictFcn(zscoredatos3);

y31 = msvm_range.predictFcn(rangedatos3);
y32 = lsvm_range.predictFcn(rangedatos3);
y33 = ebost_range.predictFcn(rangedatos3);
```

Desnormalización

A diferencia de lo que ocurre con los modelos entrenados con bases de datos sin normalizar, para el caso de estos modelos es necesario desnormalizar los resultados obtenidos con su estimación, puesto a que como se mencionó anteriormente, estos valores se encuentran escalados a una distribución normal o a un rango específico respectivamente, por lo que es necesario desnormalizar la variable respuesta utilizando la ecuación respectiva de cada método de normalización.

```
for i=1:filas
    y21fit(i) = y21(i)*P50std + P50mean;
    y22fit(i) = y22(i)*P50std + P50mean;
    y23fit(i) = y23(i)*P50std + P50mean;

    y31fit(i) = y31(i)*(P50max - P50min) + P50min;
    y32fit(i) = y32(i)*(P50max - P50min) + P50min;
    y33fit(i) = y33(i)*(P50max - P50min) + P50min;

y21fit = y21fit';
y22fit = y22fit';
y23fit = y23fit';
y31fit = y31fit';
y32fit = y32fit';
y33fit = y33fit';
end
```



4 ANÁLISIS DE RESULTADOS

4.1 RESULTADOS DE LA ESTIMACIÓN DE FRAGMENTACIÓN CON MODELOS EMPÍRICOS

Los resultados obtenidos de las estimaciones para el tamaño P50, utilizando ambos modelos se encuentran a continuación en la Tabla 9 y Figura 13

Tabla 9: Estimación de fragmentación utilizando modelos empíricos

	MAE	MSE	RMSE	R ²
Kuz-Ram	154.6288	2.5786e+04	160.5802	-24.7389
KCO	216.9898	4.8086e+04	219.2861	-46.9986

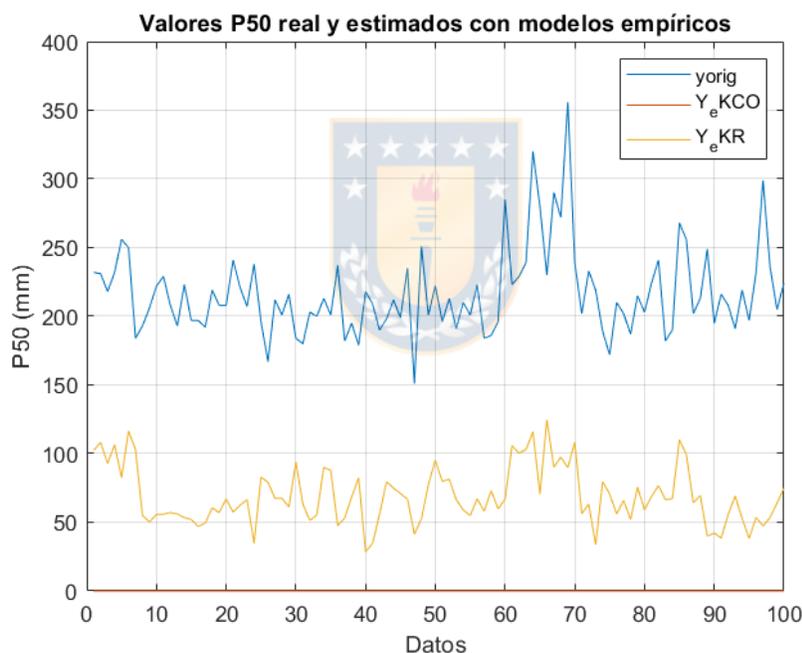


Figura 13: Gráfico comparativo de la estimación utilizando modelos empíricos con respecto a la variable original

De acuerdo con los resultados obtenidos queda en evidencia ciertas falencias de ambos modelos en términos de su habilidad para predecir el P50, esto se puede ver en los valores de las métricas de ajuste de la estimación, donde es posible apreciar los altos valores de los diferentes tipos de errores, específicamente el orden de magnitud que alcanza el error medio absoluto, el cual expone errores del orden de los 150 mm y 200 mm de error en los modelos KR y KCO respectivamente. Por otra parte, se puede ver en la última columna de la tabla que para ambos modelos el valor de

R^2 es negativo, esto se puede interpretar como si la relación entre los modelos y la variable respuesta fuera nula.

4.2 ESTIMACIÓN DE FRAGMENTACIÓN UTILIZANDO MÁQUINAS DE APRENDIZAJE

Según lo mencionado en el capítulo anterior se pueden ver los resultados de la estimación utilizando los mejores 5 algoritmos entrenados con la base de datos sin normalizar (Tabla 10) donde se puede ver un ajuste superior al previsto en la sesión de entrenamiento a excepción de lo que ocurrió para el modelo *Coarse SVM* el cual tuvo un desempeño similar al esperado según las cifras de entrenamiento.

Tabla 10: Resultados de estimación de 5 mejores modelos entrenados

	MAE	MSE	RMSE	RSQ
Fine Tree	11.5580	263.0050	16.2174	0.7375
Medium SVM	14.4112	466.2982	21.5939	0.5346
EBagged Tree	14.9768	460.0824	21.4495	0.5408
Exponential GPR	12.1920	301.9602	17.3770	0.6986
Coarse SVM	17.7775	705.3435	26.5583	0.2959

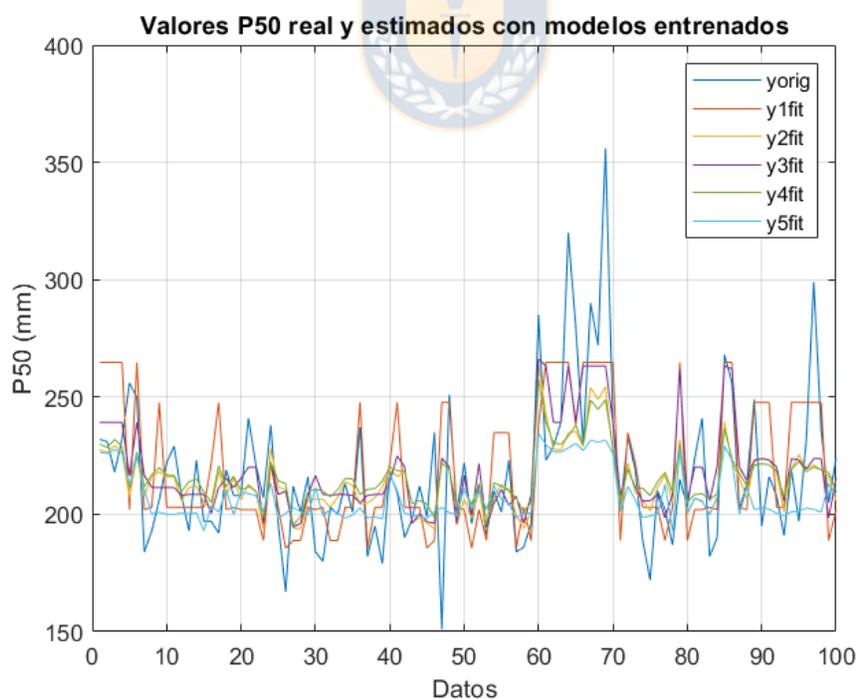


Figura 14: Gráfico comparativo de capacidad estimativa de modelos entrenados con ML

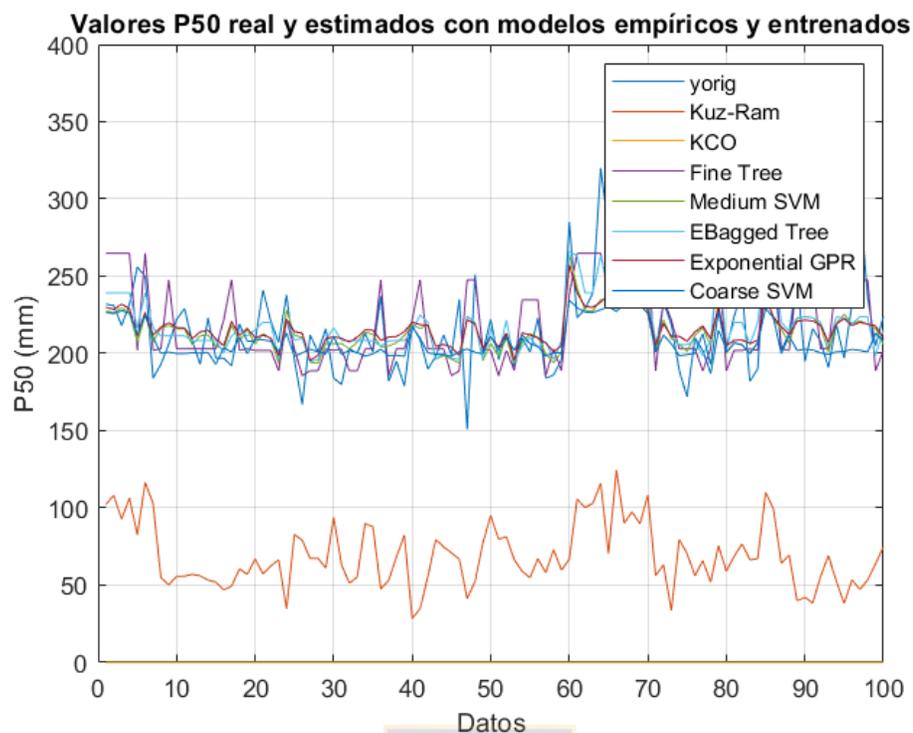
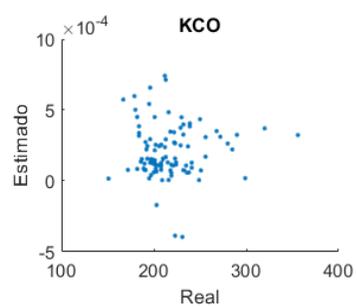
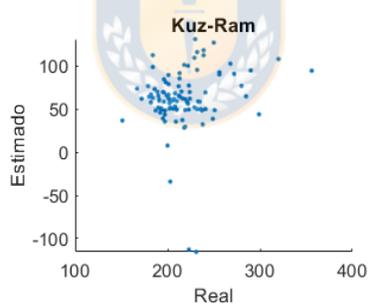


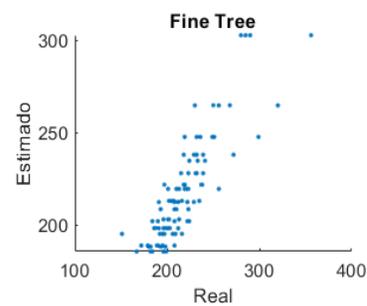
Figura 15: Gráfico comparativo de capacidad estimativa de modelos empíricos y modelos entrenados



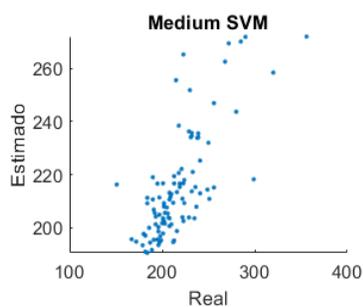
(a)



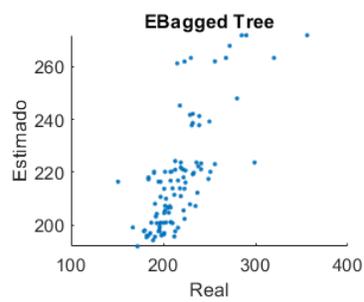
(b)



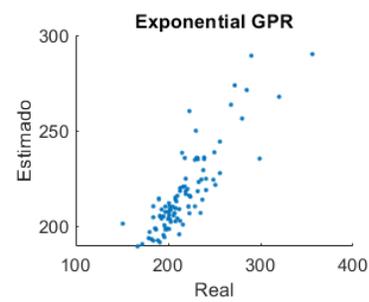
(c)



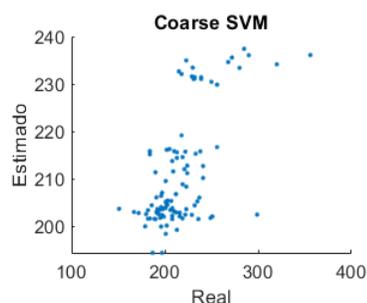
(e)



(f)



(d)



(g)

Figura 16: Gráficos "Real vs. Estimado" para los modelos empíricos y entrenados

Según se puede apreciar en las Figuras 16 y 17, existe una notable mejora en la estimación de la variable P50 en comparación con los modelos empíricos probados en la sección anterior, puesto que, para el caso de los modelos entrenados con ML, se produce una disminución en el orden de magnitud de los errores y un aumento en la bondad de ajuste. Esto toma relevancia considerando que estos modelos no cuentan con una cantidad de parámetros mínimos para ser entrenados, lo que se puede ver como una ventaja en comparación con los modelos empíricos.

4.2.1 Estimación de fragmentación utilizando variables normalizadas

Los resultados obtenidos de la estimación utilizando modelos entrenados con bases de datos normalizadas se pueden ver resumidos en la Tabla 11 y

Tabla 12, donde se puede apreciar una mejora en la estimación para la base *zscore* en relación con el entrenamiento y estimación para una base de datos sin normalizar, esto debido a los diferentes ordenes de magnitud que se presentan en una base de datos sin normalizar y a la distribución "normal" que presentan algunas de las variables de la base de datos.

Tabla 11: Resultados estimación utilizando base de datos normalizada zscore

	MAE	MSE	RMSE	RSQ
Exponential GPR	11.4387	256.7301	16.0228	0.7437
EBoosted Tree	10.4745	241.5040	15.5404	0.7589
Matern 5/2 GPR	14.2588	396.7295	19.9181	0.6040

Tabla 12: Resultados estimación utilizando base de datos normalizada range

	MAE	MSE	RMSE	RSQ
Medium SVM	14.2495	452.3392	21.2683	0.5485
Linear SVM	15.9481	530.2171	23.0264	0.4708
EBoosted Tree	11.5135	279.0659	16.7053	0.7214



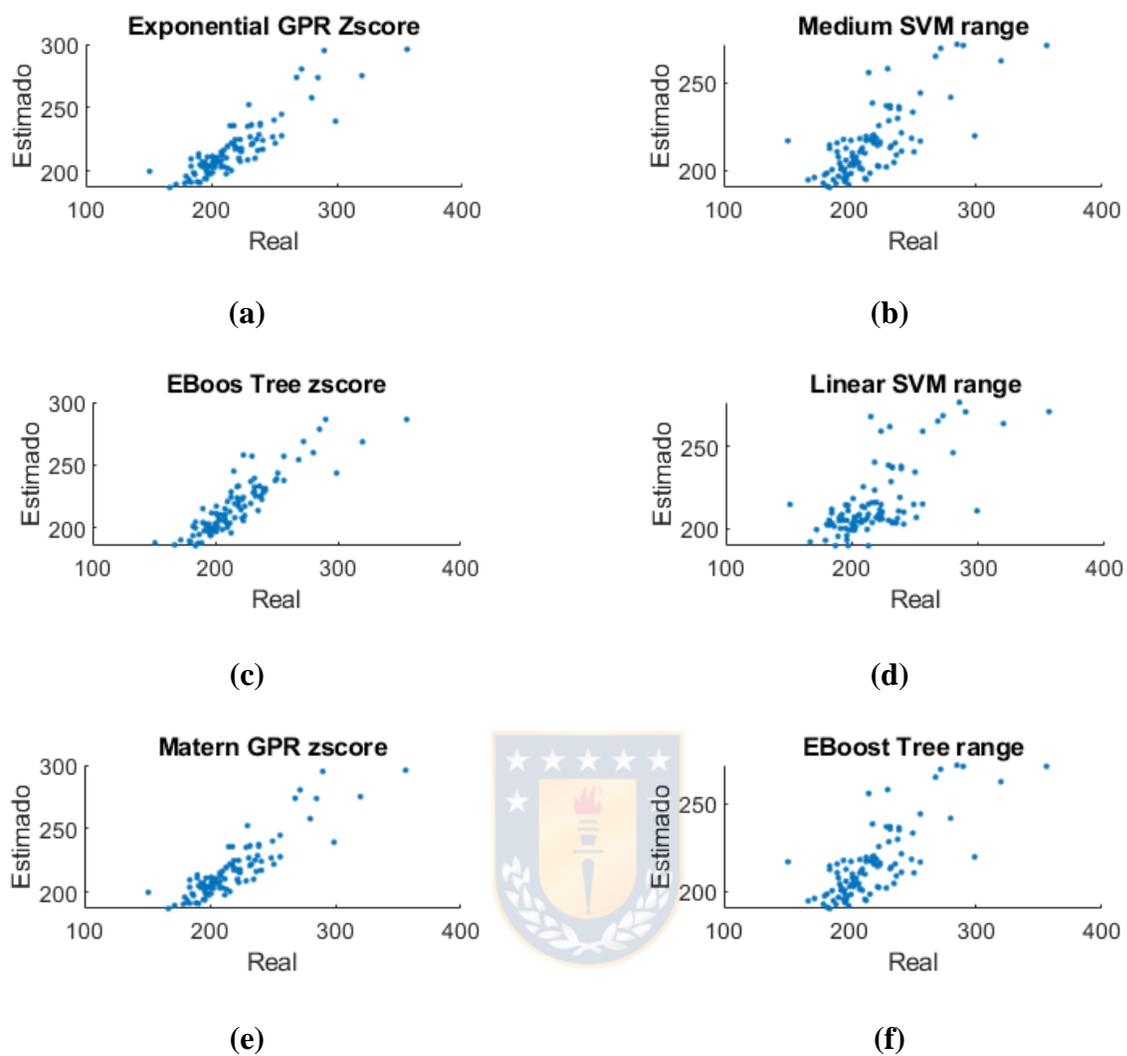


Figura 17: Gráficos "Real vs Estimado" para bases normalizadas

5 CONCLUSIONES Y RECOMENDACIONES

La fragmentación cumple un rol primordial en la industria minera, sin embargo, en la práctica, es curioso el hecho de que su control sea generalmente delegado como responsabilidad de empresas externas proveedoras de servicios de tronadura (EPE), ya que al volverse parte de su potestad, abre la posibilidad de que se vea manipulada con el fin de atender intereses estratégicos y comerciales, por lo que se esperaría que un aspecto tan relevante para la operación se encuentre bajo supervisión y auditoría de la empresa mandante. Por otro lado, se debe considerar que, cuando existe, el ingeniero encargado de estas labores también debe responder a temas operacionales, de costos y seguridad. En ese sentido, se ve en la necesidad de priorizar ciertas actividades y, desatender algunas de sus funciones técnicas relacionadas a la fragmentación. Esto puede ser consecuencia de la falta de recursos dentro de la empresa, lo que se traduce en la ausencia de personal especializado al que se le permita dedicarse a tareas exclusivas. Por consiguiente, dependerá en gran medida del organigrama que se presente dentro de la operación, para entender quién resultará responsable de los efectos que pueda tener una buena o mala fragmentación. La principal consecuencia de esto es que se produce una pérdida de la excelencia operacional, reduciendo las oportunidades de desarrollo de nuevos modelos, innovación o mejora de los existentes.

Tomando como base lo anterior, sumado a que los modelos predictivos utilizados en la industria, en la práctica, no son tan efectivos para la estimación de fragmentación. Se indagó en la incorporación de herramientas con inteligencia artificial, como son los algoritmos de Machine Learning, para mejorar la estimación de fragmentación generando modelos predictivos que permitan tener una mejor estimación, para así poder controlar y aprovechar los beneficios que esto puede tener dentro de una operación.

Con la información existente en el interior de una operación minera es suficiente para generar una buena estimación de la fragmentación, pues se cuenta con los antecedentes mínimos para crear un diseño de extracción que arroje buenos resultados. Sin embargo, no siempre estas referencias son bien aprovechadas, en consecuencia, de que no se es consciente del potencial o el valor que esta puede tener para otras actividades ligadas dentro de la mina, por ende, no se cuenta con un concepto global de como las tareas que se realizan están interrelacionadas entre sí.

En lo que respecta la implementación de ML, se puede decir que no es necesario incurrir en gastos, equipos o maquinaria adicionales para acceder a una mejor estimación de la fragmentación, pues como se mencionó anteriormente, la información existe y se ve empleada en otras etapas del proceso. Sin embargo, es necesario contar con profesionales mineros capacitados en el área del Data Science; para el manejo de datos, desarrollo de modelos, análisis de sus resultados e interpretación de estos en un contexto del negocio minero.

En base a lo anterior y cumpliéndose estos tres factores: valoración del tiempo experto, disponibilidad y representatividad de la información y, por último, contar con un profesional que tenga las competencias necesarias. Según como queda demostrado en el capítulo anterior, es posible obtener una estimación de la fragmentación más cercana a la realidad que la que se obtiene utilizando modelos empíricos como son el Kuz-Ram y el KCO.

En general, con este tema, se puede concluir que la incorporación de modelos predictivos generados con ML presenta una serie de ventajas. En primer lugar, relacionadas con la implementación, en efecto el entrenamiento de estos se puede llevar a cabo a través de aplicaciones en softwares de programación como es el *Regression Learner* (MATLAB), o en otros lenguajes de programación como R o Python. Adicionalmente, se puede decir que se trata de una metodología altamente competitiva en relación con los modelos empíricos, con referencia a que esta no requiere una mínima cantidad de información o de parámetros. Por lo tanto, es posible entrenar los algoritmos con los datos existentes y disponibles dentro de la mina. Esto le entrega versatilidad en cuanto a su aplicación, lo que no descarta que, el hecho de disponer de más información, o en su defecto, información más representativa, va a permitir entrenar modelos que entreguen predicciones más exactas.

Los modelos predictivos generados con algoritmos de ML serán menos flexibles, pero más exactos, porque se entrenan para una operación específica con ciertos patrones en su naturaleza que limitarán el uso de estos modelos en otras minas. Por ello es por lo que los antecedentes utilizados solo serán válidos para la faena en la cual ese entrenó el modelo. Sin embargo, se obtendrán mejores resultados que al aplicar modelos más robustos como son los modelos empíricos, ya que, si bien estos se pueden aplicar para cualquier operación, también requieren de una calibración acorde a la mina con el fin de mejorar el desempeño de su estimación. A pesar de lo anterior, los modelos empíricos siguen

siendo una alternativa practica para estimar fragmentación que no requiera de gran exactitud, algunas de las causas que pueden tener como consecuencia su bajo desempeño pueden ser las siguientes:

- Dentro de los modelos empíricos más utilizados en la industria, se puede decir que, ninguno incorpora dentro de su formulación la relación de rigidez que se da entre el burden y la altura de banco, siendo que ésta es una forma de pre estimar la fragmentación producida durante la tronadura y el desplazamiento del material tronado.
- En la estimación con estos modelos, es necesario considerar que algunos parámetros fueron fijados de manera arbitraria, puesto que, de forma directa o indirecta, no se incluyeron en la base de datos recepcionada, lo que seguramente tuvo un efecto negativo en la estimación con los modelos Kuz-Ram y KCO.

Teniendo en cuenta lo anterior y, considerando que el entrenamiento y aplicación de los modelos fueron realizados con la misma base de datos, los modelos predictivos entrenados con ML presentaron un mejor ajuste de estimación y errores mucho menores que los obtenidos con modelos empíricos.

En cuanto a las variables utilizadas como predictores, se puede decir que los mejores modelos fueron en general, los que no contaron con la variable burden ni tiempo entre pozos, las cuales presentaron débiles correlaciones y una independencia basada en las pruebas estadísticas con respecto a la variable respuesta. Sin embargo, es necesario tener en consideración que los valores obtenidos de *p-value* en las pruebas no fue superior a 0.5 para todos los predictores en cuestión, por lo que no se puede desechar completamente la opción de que estas estén relacionadas entre sí. Quizás una alternativa para mejorar esta situación sea contar con una base de datos de mayor tamaño, y que cuyos antecedentes contengan una mayor cantidad de variables referentes a la caracterización de roca o proveniente de mediciones realizadas durante la tronadura.

En lo que respecta al mejor modelo (*Fine Tree*) este fue un modelo que no incorporó las variables burden, módulo de Young, velocidad de detonación ni densidad de roca. Siendo estas últimas tres variables las que presentaban una mayor correlación tanto directa como inversa con la variable respuesta, lo cual puede deberse a relaciones no lineales, no monótonas o simplemente a la influencia de un predictor sobre otro en la relación con la variable respuestas (interacciones entre variables). Esta situación además llamó la atención porque durante las iteraciones realizadas hasta el algoritmo se pudo apreciar un aumento generalizado del RMSE y una disminución del R^2 por lo que se presume

que esta situación puede, en parte, atribuírsele a la arquitectura del algoritmo, el cual al ser de tipo “fino” no presenta un gran número de ramificaciones lógicas, lo que pudo tener como consecuencia el hecho de no influirle el comportamiento categórico de las variables. Finalmente, las variables constantes de diámetro y radio de pozo no se utilizaron como predictores puesto que se mostraban constantes y presentaron nula correlación con la variable respuesta.

En lo concerniente al impacto de la normalización de la base de datos, se pudo apreciar una mejora en la estimación en algoritmos con bases normalizadas mediante *zscore*. Gracias a esto todos los predictores aportan información independiente de su orden de magnitud, lo que permite tener una mejor idea de que variables son las que entregan más información a la hora de estimar y cuáles no.

En función de las conclusiones, se recomienda para futuras investigaciones realizar un estudio de la implementación de un modelo en tiempo real para poder revisar diseños de malla y secuencias de tronadura de manera casi instantánea, donde el algoritmo pueda entrenarse periódicamente en base a los datos captados de manera continua al interior de la operación, o en su defecto, se recomienda la adquisición de un sistema SCADA para la captación y control de información proveniente de todas las operaciones unitarias que estén interrelacionadas con la perforación y tronadura. De esta manera sería posible obtener el mayor beneficio de estas herramientas, lo que le permitiría obtener aún mejores resultados en proyectos de tipo mina-planta

Otra variante de esto puede ser la posibilidad de desarrollar modelos predictivos específicos para cada UGT, debido a que estas reúnen una serie de características en común que pueden provocar que ciertos predictores tengan una relación distinta con las variables respuesta comparada con la que se presenta dentro de una base de datos general de la operación.

Finalmente, en consideración a lo estudiado, se puede decir que el ML ofrece un gran potencial para las ciencias de la ingeniería en general. Por lo que es posible ampliarlo no solo a temas de estimación de fragmentación producto de la tronadura, como se realizó en el presente trabajo, sino que también a otras áreas de la minería mediante la utilización de algoritmos de clasificación para elegir entre litologías, diseños de malla, secuencias de tronadura, etc. Por lo que es realista pensar que este tipo de investigaciones dará paso a un nuevo tipo de minería donde se obtengas mejores resultados, tanto en temas de producción como en temas económicos, haciendo hincapié en que el personal esté capacitado y se le permita desempeñarse de forma íntegra en sus funciones. Si a estas

condiciones se le suma la integración de la inteligencia artificial y herramientas de automatización, estaremos en presencia de lo que ahora se denomina como la “minería del futuro”.



REFERENCIAS

- [1] J. Cubillos Miranda, Interviewee, *Perforacion y Tronadura en una operacion Minera*. [Entrevista]. 17 Julio 2020.
- [2] S. S. Kanchibotla, W. Valery y S. Morrel, «Modelling fines in BLast Fragmentation and its Impacto on crushing and griding,» Julius Kruttschnitt Mineral Research Centre, Brisbane, Australia.
- [3] B. A. Kansake, V. Temeng y B. Afum, «Comparative Analysis of Rock Fragmentation Models - A Case Study,» de *4th UMaT Biennial International Mining and Mineral Conference*, 2016.
- [4] B. R. Murlidhar, D. J. Armaghani, E. T. Mohamad y S. Changthan, «Rock Fragmentation Prediction through a New Hybrid Model Based on Imperial Competitive Algorith and Neural Network,» 2018.
- [5] ISO, ISO 9001:2015 specifies requirements for a quality management system when an organization, 2015.
- [6] H. Jang, I. Kitahara, Y. Kawamura y E. Topal, «Development of 3D rock fragmentation measurement system using photogrammetry,» *International Journal of Mining Reclamation and Enviroment*, March 2019.
- [7] S. Ho Cho y K. Kaneko, «Rock Fragmentation Control in Blasting,» *Materials Transactions*, Vol. 45, No. 5, pp. 1722 - 1730, 2004.
- [8] S. Esen, I. Onederra y H. Bilgin, «Modelling the size of the crushed zone around a blasthole,» *International Journal of Rock Mechanics and Mining Sciences*, vol. 40, pp. 485-495, 2003.
- [9] F. Ouchterlony, «The Swebrec Function: Linking fragmentation by blasting and crushing,» *Transactions of the Institution of Mining and Metallurgy*, pp. A29-A44, 2005.

- [10] R. Yang, «Relate peak particle Velocity of Seismic Wave to 3D Dynamic Strain,» *Rock Mechanics and Rock Engineering*, 2016.
- [11] R. Yang, «A Multiple Blasthole Fragmentation Model - Its concept, formulation, capability and field comparison examples,» de *11TH INTERNATIONAL SYMPOSIUM ON ROCK FRAGMENTATION BY BLASTING*, SYDNEY, NSW, 2015.
- [12] R. Yang, C. McAllister, J. Berendzen y D. Preece, «Fragmentation modeling using the multiple blasthole fragmentation (MBF) model at an openpit mine,» *Minning Engineering Magazine*, pp. 49-55, 2016.
- [13] S. Xiu-Zhi, Z. Jian, W. Bang-biao, H. Dan y W. wei, «Support Vector Machines approach to mean particle size of rock fragmentation due to bench blasting prediction,» *Transactions of Nonferrous Metals Society of China*, pp. 432-441, 2012.
- [14] A. Sayadi, M. Monjezi, N. Talebi y M. Khandelwal, «A comparative study on the application of various artificial neural networks to simultaneous prediction of rock fragmentation and backbreak,» *Journal of Rock Mechanics and Geotechnical Engineering*, pp. 318-324, 2013.
- [15] F. Farmarzi, H. Mansouri y M. E. Farsangi, «A rock engineering system based model to predict rock fragmentation by blasting,» *International Journal of Rock Mechaniscs & Mining Sciences*, pp. 82-94, 2013.
- [16] N. Brook, «Rock Testing and Site Characterization - Compressive Rock Engineering,» *International Journal Rock Mechanics Science and Geomechanics*, vol. 22, pp. 41-66, 1993.
- [17] R. Nazir, E. Momeni y D. J. Armaghani, «Correlation between unconfined compressive strenght and indirect tensile strenght of limestone rock sample,» *EJGE*, vol. 18, pp. 1737-1747, 2013.
- [18] C. A. Canoba y H. R. Fraga, «Propiedades elasticas de las rocas (traduccion),» Departamento de Ciencias Geologicas, Universidad Nacional de Rosario, Rosario, 2004.
- [19] L. Ortiz Berrocal, «Resistencia de Materiales,» Madrid, España, McGraw-Hill, 2007, p. 834.

- [20] V. Marinos, M. P. y E. Hoek, «The Geological Strength Index: Applications and limitations,» *Bulletin of Engineering Geology and the Environment*, vol. 64, pp. 55-65, 2015.
- [21] R. Gomez, *Apuntes clase Mecanica de Rocas: Clasificacion de Macizo Rocoso*, Concepcion: Universidad de Concepcion, 2017.
- [22] Konya, *Manual de Voladura*, 1990.
- [23] R. B. Morrison, «A shock tube investigation of detonative combustion,» University of Michigan, Michigan, 1952.
- [24] L. Jimeno, *Manual de Perforacion y Voladura de Rocas*, España: Instituto Tecnológico Geominero de España.
- [25] M. Saliu, A. Akindoyeni y I. Okewale, «Correlation between Blast Efficiency and Uniaxial Compressive Strength,» *International Journal of Engineering and Technology*, pp. 805-811, 2013.
- [26] L. Muñoz Tolosa, «Uso del "Crush Zone Model" para el modelamiento de finos generados por voladura con explosivos de alta energia,» de ASIEX, Santiago, Chile, 2017.
- [27] E. Kabwe, «Velocity of detonation measurement and fragmentation analysis to evaluate blasting efficacy,» *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 10, pp. 523-533, 2018.
- [28] C. V. B. Cunningham, «The Kuz-Ram fragmentation model, 20 years on,» de *Brighton Conference PROCEEDINGS*, Brighton, 2005.
- [29] V. M. Kuznetsov, «The Mean Diameter of the fragments formed by blasting rock,» Institute of Mining, Siberian Branch, Academy of Sciences of the USSR, Novosibirsk, 1973.
- [30] N. Djordjevic, «Image based modeling of rock fragmentation,» *Minerals Engineering*, pp. 68-75, 2013.

- [31] N. Djordjevic, «Two-Component Model of Blast Fragmentation,» Julius Kruttschnitt Mineral Research Center, Brisbane, Australia, 1999.
- [32] I. Villalba Montoya y M. L. Delgado, «Modelos Predictivos de Fragmentacion,» Enex.
- [33] A. T. Elahi y M. Hosseini, «Analysis of blasted rocks fragmentation using digital image procesing (case study: limestone quarry of Abyek Cement Company),» *International Journal of Geo-Engineering*, pp. 8-16, 2017.
- [34] I. C. Engin, N. H. Maerz, K. J. Boyko y R. Reals, «Practical Measurement of Size Distribution of Blasted Rocks Using LiDAR Scan Data,» *ROck Mechanics and Rock Engineering*, 2020.
- [35] J. M. Kemeny, A. Devgan, R. M. Hagaman y X. Wu, «Analysis of rock fragmentation using digital image processing,» *J. Geotech*, pp. 1144-1160, 1993.
- [36] R. O'Meara, *A practical overview of fragmentation measurement systems*, Orica, 2018.
- [37] J. Sanchidrian, P. Segarra y L. Lopez, «A Practical procedure for the measurement of fragmentation by blasting by image analysis,» *Rock Mechanics and Rock Engineering*, pp. 359-382, 2006.
- [38] B. K. Singh, D. Mondal, M. Shahid, A. Saxena y P. N. Singha Roy, «Application of digital image analysis for monitoring the behavior of factors that control the rock fragmentation in opencast bench blasting: A case study conducted over four opencast coal mines of the Talcher Coalfields, India,» *Journal of Sustainable Mining*, vol. 18, pp. 247-256, 2019.
- [39] A. Roman G, «Analisis de Imagenes digitales,» *Revista ECIPeru*, vol. 9, pp. 61-68, 2012.
- [40] R. Yang, C. Ding, L. Yang, Z. Lei, Z. Zhang y Y. Wang, «Visualizing the blast induced stress wave and blasting gas action effects using digital image correlation,» *International Journal of Rock Mechanics and Mining Science*, pp. 47-54, 2018.
- [41] Mathworks, *Statistical and Machine Learning user's guide*, MATLAB, 2020.

- [42] H. Gorr, M. Gavilan-Alfonso, B. Armstrong y e. al., *Predictive Modeling and Machine Learning with MATLAB*, Mathworks, 2020.
- [43] A. Fillion, M. Gavilan-Alfonso, B. Armstrong y e. al., *Data Processing and Feature Engineering with MATLAB*, Mathworks, 2020.
- [44] G. James, D. Witten, T. Hastie y R. Tibshirani, *An introduction to statistical learning with applications in R*, Springer, 2013.
- [45] A. Torres, «Diseño e implementación de un algoritmo de obtención automática de modelos dinámicos discretos,» Facultad de Ingeniería, Universidad de Concepcion, Concepcion, 2021.
- [46] A. L. Torres, «Influencia de la optimizacion de la fragmentacion de roca en la rentabilidad de las operaciones mina-molienda,» Pontificia Universida Católica del Peru, Lima, Perú, 2007.
- [47] ASP Quality Press, «aqsp.org,» American Society for Quality, 2020. [En línea]. Available: <https://asq.org/quality-resources/pdca-cycle>.
- [48] L. M. Tolosa, Interviewee, *Estimacion de Fragmentacion*. [Entrevista]. 5 agosto 2020.
- [49] C. C. U.E.A. Carolina I, «Sistema Integrado de Gestion SSYMA - Voladura,» Gold Fields, Peru, 2012.
- [50] W. E. Deming, *Calidad, Productividad y Competitividad: la salida de la crisis*, Madrid: Diaz de Santos, 1989.
- [51] H. Abbaspour, B. A. Kansake y C. Drebenstedt, «Unraveling the Capability of Artificial Intelligence for Prediction of Rock Fragmentation,» de *Scientific Publication of the deparment for Mine Surveing and Geodesy of The University of Thechnology Begakademie Freiberg*, Freiberg, 2019.
- [52] S. Kanchibotla, W. Valery y S. Morrel, «Modelling fines in BLast Fragmentation and its Impacto on crushing and griding,» Julius Kruttschnitt Mineral Research Centre, Brisbane, Australia, 1999.

- [53] S. Donoso Rodriguez, «ANÁLISIS DE LOS FACTORES CONTRIBUYENTES EN LA PÉRDIDA DEL ANCHO EN LA FASE 10N DE MINA LOS PELAMBRES,» Universidad de Chile, Santiago de Chile, 2020.
- [54] K. Phamotse y A. Nhleko, «Determination of optimal fragmentation curves for a surface diamond mine.,» The Southern African Institute of Mining and Metallurgy, 2019.
- [55] B. Ramesh Murlidhar, D. Jahed Armaghani, E. Tonnizam Mohamad y S. Changthan, «Rock Fragmentation Prediction through a New Hybrid Model Based on Imperial Competitive Algorithm and Neural Network,» de *Smart Construction Research*, 2018.
- [56] P. Singh, M. Roy, R. Paswan, M. Sarim, S. Kumar y R. R. Jha., «Rock fragmentation control in opencast blasting,» *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 8, pp. 225-237, 2016.
- [57] S. Shams, M. Monjezi, V. J. Majd y D. J. Armaghani, «Application of fuzzy inference system for prediction of rock fragmentation induced by blasting,» *Saudi Society for Geosciences*, 2015.
- [58] M. Nefis y K. Talhi, «A model study to measure fragmentation by blasting,» *Mining Science*, vol. 23, pp. 91-104, 2016.
- [59] T. Zhao y Y. Liu, «A novel random discee element analysis of rock fragmentation,» *International Journal for Numerical and Analytical Methods in Geomechanics*, 2020.

ANEXOS

Anexo A: Caracterización de roca por UGT

```
for i=1:filas
    if datos.UGT(i) == "UGT1"
        rho(i) = 2.61 ; % ton/m3
        UCS(i) = 82.91 ; % MPa
        E(i) = 29.54 ; % GPa

    elseif datos.UGT(i) == "UGT2"
        rho(i) = 2.57 ; % ton/m3
        UCS(i) = 79.3 ; % MPa
        E(i) = 22.91 ; % GPa

    elseif datos.UGT(i) == "UGT3"
        rho(i) = 2.48 ; % ton/m3
        UCS(i) = 76.74 ; % MPa
        E(i) = 19.10 ; % GPa

    elseif datos.UGT(i) == "UGT5"
        rho(i) = 2.69 ; % ton/m3
        UCS(i) = 60.7 ; % MPa
        E(i) = 27.59 ; % GPa

    elseif datos.UGT(i) == "UGT6"
        rho(i) = 2.40 ; % ton/m3
        UCS(i) = 73.97 ; % MPa
        E(i) = 17.85 ; % GPa

    elseif datos.UGT(i) == "UGT7"
        rho(i) = 2.7 ; % ton/m3
        UCS(i) = 150 ; % MPa
        E(i) = 20 ; % GPa

    elseif datos.UGT(i) == "UGT9"
        rho(i) = 2.7 ; % ton/m3
        UCS(i) = 150 ; % MPa
        E(i) = 20 ; % GPa

    elseif datos.UGT(i) == "UGT11"
        rho(i) = 2.40 ; % ton/m3
        UCS(i) = 96.86 ; % MPa
        E(i) = 24.22 ; % GPa
```



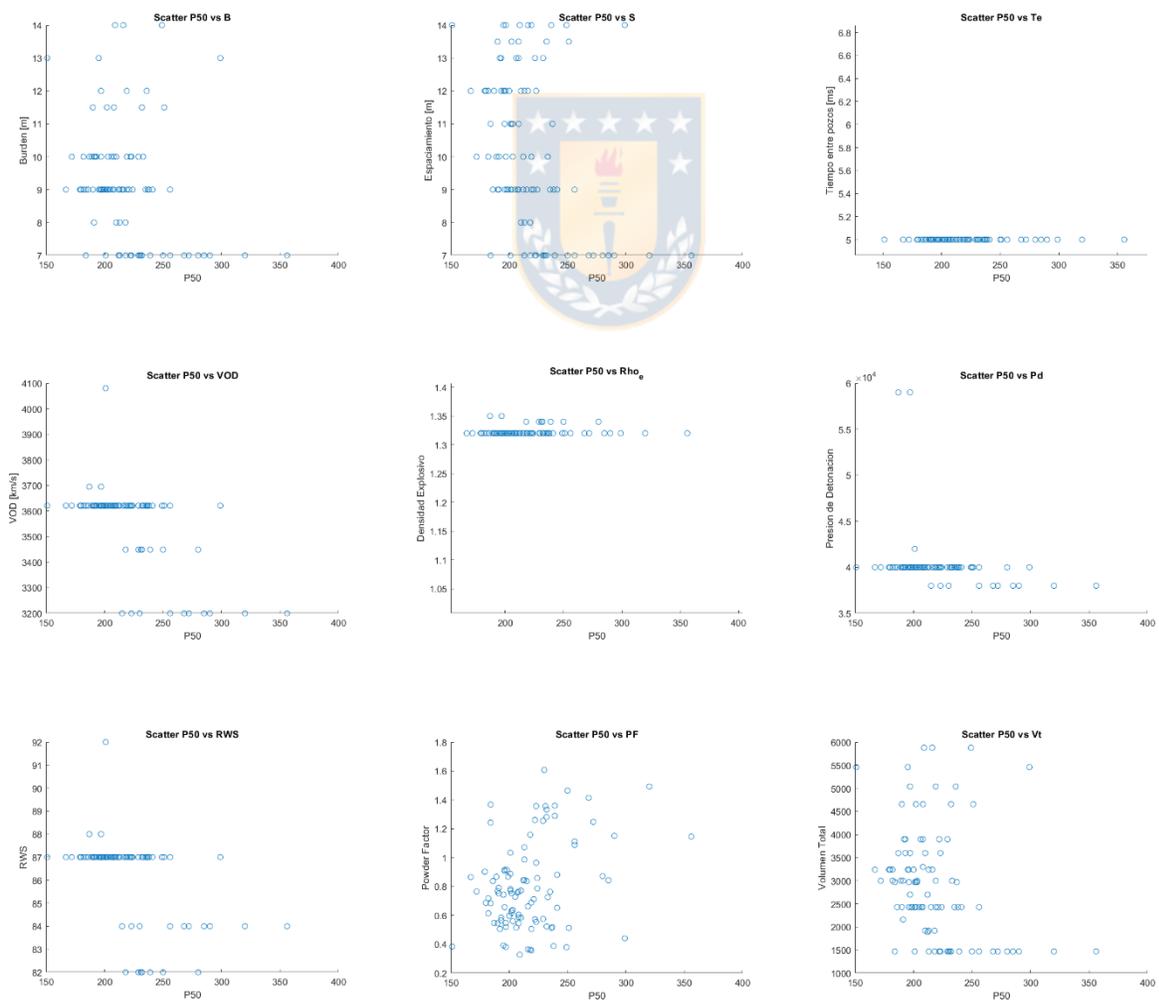
```

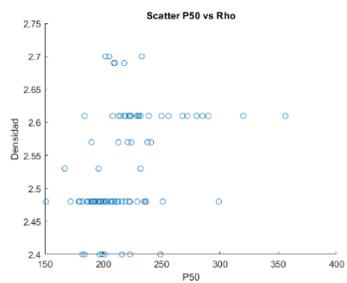
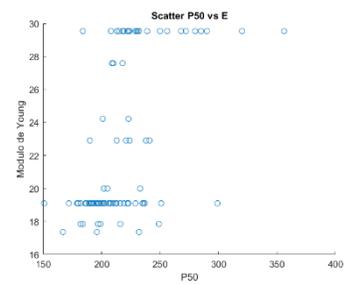
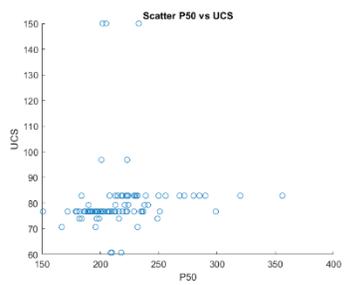
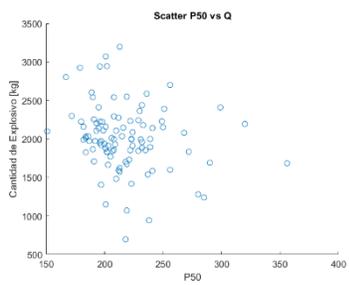
elseif datos.UGT(i) == "UGT12"
    rho(i) = 2.53 ; % ton/m3
    UCS(i) = 70.73 ; % MPa
    E(i) = 17.36 ; % GPa

end
end
rho = rho';
UCS = UCS';
E = E';

```

Anexo B: Gráfico de correlación de variables





UNIVERSIDAD DE CONCEPCIÓN - FACULTAD DE INGENIERÍA
Departamento de Ingeniería Metalúrgica
Hoja Resumen Memoria de Título

Título: Estimación de la fragmentación producto de la tronadura de rocas en minería a cielo abierto utilizando modelos predictivos y algoritmos de regresión		
Nombre Memorista: Fernanda José Rojas Valenzuela		
Modalidad	Investigación	Profesor (es) Patrocinante (s)
Concepto	Muy Bueno	Prof. Jorge Cubillos M.
Calificación	6.7	
Fecha	30-03-2021	
 Prof. FERNANDO PARADA		Ingeniero Supervisor:
		Institución:
Comisión (Nombre y Firma)		
 Prof ^a . Asieh Hekmat		 Prof. Roberto Fustos T.
Resumen		
<p>El presente trabajo surge de la necesidad de proponer como mejorar la estimación de fragmentación producto de la tronadura en minería a cielo abierto, para lo cual se desarrolló una investigación aplicada con la finalidad de entender cómo es que se produce la estimación de fragmentación desde un punto de vista teórico, y también, exponer cómo es que ésta se integra dentro de un proceso industrial. Para esto se realizó una exhaustiva investigación de los modelos empíricos utilizados y se indagó en el contexto industrial en el que estos son aplicados.</p> <p>En este contexto surge la idea de la aplicación de algoritmos de máquinas de aprendizaje, conocidos como algoritmos de Machine Learning (ML) para la estimación de fragmentación, basándose en una serie de estudios realizados con otras herramientas de la inteligencia artificial aplicadas a la estimación de fragmentación. De este modo se determinó que el objetivo general fuese indagar si la estimación de fragmentación, específicamente el P50, podría ser eventualmente mejorada mediante la incorporación de algoritmos de Machine Learning.</p> <p>Tras perseverar en la búsqueda de recursos y enfrentar una serie de limitaciones, fue posible acceder a una base de datos provenientes de Minera Los Pelambres con información de diseño, explosivo y granulometría. Esta permitió realizar la estimación de fragmentación utilizando los modelos Kuz-Ram y Kuznetsov-Cunningham-Ouchternoly (KCO), donde se obtuvo un R2 nulo para ambos modelos y altos valores del error cuadrático medio. Posteriormente se entrenaron varios modelos utilizando la aplicación Regression Learner de MATLAB combinando diferentes predictores, donde se obtuvieron una serie de modelos predictivos entre los cuales, el mejor resultado de estimación fue uno basado en arboles de decisión, el que tuvo una bondad de ajuste del 0.73 y un RMSE de 16.21 utilizando una base de datos sin normalizar. Adicionalmente se estudió el impacto que tiene en la estimación la normalización de la base de datos, debido a la variedad en los órdenes de magnitud de las variables involucradas.</p> <p>Finalmente, en base a los resultados obtenidos, se pudo concluir que existe un gran potencial en la incorporación de algoritmos de regresión para la estimación de la fragmentación, ya que estos presentan una serie de ventajas relacionadas a la cantidad mínima de información requerida para su aplicación y a un mejor desempeño en comparación con los modelos semiempíricos.</p>		

