

# Optimization of Rock Blasting Fragmentation in Open Pit Using Predictive Models

Eduardo Manuel Noriega-Vidal, Msc.<sup>1</sup>, Marco Antonio Cotrina-Teatino, Dr.<sup>1</sup>, Tomas Jubencio Anticona-Cueva<sup>1</sup>, Jaime Yoni Anticona-Cueva<sup>1</sup>, Jhon Kener Vera-Encarnación<sup>1</sup>, Alan Yordan Valdiviezo-Velarde, Dr.<sup>2</sup>

<sup>1</sup>Departamento de Ingeniería de Minas, Universidad Nacional de Trujillo, Perú, [emnoriegav@unitru.edu.pe](mailto:emnoriegav@unitru.edu.pe), [mcotrinat@unitru.edu.pe](mailto:mcotrinat@unitru.edu.pe), [tanticona@unitru.edu.pe](mailto:tanticona@unitru.edu.pe), [jyanticona@unitru.edu.pe](mailto:jyanticona@unitru.edu.pe), [jkverae@unitru.edu.pe](mailto:jkverae@unitru.edu.pe)

<sup>2</sup>Director de Ingeniería Civil, Universidad César Vallejo, Perú, [avaldivieso@ucv.edu.pe](mailto:avaldivieso@ucv.edu.pe)

**Resumen**– La presente investigación tuvo como objetivo principal optimizar la fragmentación de la voladura de rocas en open pit mediante modelos predictivos. Para ello, se trabajó con 47 muestras de registros de voladuras de una mina open pit y se programó un modelo de red neural artificial (ANN) en Python 3.11.4. Se escogió de forma aleatoria el 80% de muestras para realizar el entrenamiento del ANN y 20% para el testeo. En la arquitectura de la red neural artificial se incluyó tres capas (entrada, oculta y salida), en esta se utilizó 8 neuronas para los parámetros de input y 13 neuronas ocultas, enfocando como resultado de salida el P80, P50 y P20. Por último, se usó el algoritmo de entrenamiento Adam, con una tasa de aprendizaje de 0.01 y un total de 600 ciclos, para lograr minimizar el error cuadrático medio. Se obtuvo como resultado un coeficiente de correlación R2 de 0.91 para el P80. Para P20 y P50, el R2 fue de 0.62 y 0.84 respectivamente. Concluyendo que, fue posible predecir de forma aceptable la fragmentación de la voladura utilizando la ANN, y con ello lograr optimizar la fragmentación de la voladura de rocas en open pit.

**Palabras clave:** red neural artificial, optimización, algoritmo de entrenamiento Adam, Python.

**Abstract**– The main objective of this research was to optimize the fragmentation of open pit rock blasting through predictive models. To do this, we worked with 47 samples of blasting records from an open pit mine and an artificial neural network (ANN) model was programmed in Python 3.11.4. 80% of the samples were randomly chosen to carry out the ANN training and 20% for the testing. In the architecture of the artificial neural network, three layers were added (input, hidden and output), in which 8 neurons were generated for the input parameters and 13 hidden neurons, focusing on P80, P50 and P20 as the output result. Finally, the Adam training algorithm was used, with a learning rate of 0.01 and a total of 600 cycles, in order to minimize the mean square error. As a result, a connection coefficient R2 of 0.91 was obtained for the P80. For P20 and P50, the R2 was 0.62 and 0.84 respectively. Concluding that, it was possible to predict in an acceptable way the fragmentation of the blast using the ANN, and with this, to optimize the fragmentation of the rock blast in open pit.

**Keywords:** artificial neural network, optimization, Adam training algorithm, Python.

## I. INTRODUCCIÓN

En la minería open pit, los procesos de chancado y molienda son los que mayor energía consumen e impactan en la productividad; por ello, es importante realizar una buena fragmentación por voladura, para lograr una adecuada

operación en las otras operaciones como: carguío, transporte, chancado, etc.

Un adecuado enfoque sistémico de las operaciones de arranque y uso racional de la energía del explosivo permite realizar una buena fragmentación por voladura, con lo cual se reduce costos, además, permite controlar mejor las alteraciones ambientales [1].

En la fragmentación de roca, influyen parámetros como las propiedades del macizo rocoso, las cuales son variables que no se pueden controlar; por otra parte, están las variables que sí son controlables, como los parámetros de diseño de perforación y las propiedades de los explosivos. En el diseño de la perforación influye el espaciamiento, burden, taco, altura de banco, diámetro de taladro y propiedades del taladro, además, se considera el tipo de explosivo, carga específica y otros parámetros que influyen en la voladura de rocas [2]. Por ello, para predecir la fragmentación por voladura, los parámetros de diseño son los más relevantes para la optimización de este proceso.

En ese sentido, la voladura es uno de las operaciones unitarias que se controla durante el proceso productivo de la explotación de los recursos minerales; por tanto, siempre se está buscando la mejora continua en busca de resultados óptimos, los mismos que permiten reducir los costos de chancado tanto primario como secundario. Cabe mencionar que, existen numerosas metodologías que permiten tener una aproximación a los cálculos de diseño de una malla de perforación y voladura; sin embargo, es importante tener en cuenta las propiedades mecánicas de la roca para una fragmentación adecuada. La voladura está sujeta a prueba y error, por tanto, cada registro de cada una de las voladuras, permite a los ingenieros tener bajo líneas generales un comportamiento adecuado del macizo rocoso.

Al optimizar los parámetros de perforación y voladura considerando la fragmentación de rocas, se contribuye a disminuir los costos de operación y optimar la producción [3]. Por ello, la fragmentación es primordial para la operación, porque influye en los demás procesos como el de carguío, transporte y procesamiento de minerales, los cuales tienen un impacto significativo en la viabilidad y sostenibilidad de la operación minera [4].

Existen modelos matemáticos para optimizar estos procesos de fragmentación, así mismo, el empleo de diversos tipos de explosivos, caracterizados por propiedades distintas, conduce a la formación de distribuciones granulométricas, tanto finas como gruesas [5]. Los avances que se han presentado al

Digital Object Identifier: (only for full papers, inserted by LEIRD).  
ISSN, ISBN: (to be inserted by LEIRD).  
DO NOT REMOVE

realizar los diseños de las mallas de voladura, fueron realizados a través de un gran número de pruebas y sus resultados se pueden ajustar a modelos matemáticos; por ello, es importante tener un conocimiento previo de la granulometría que tendrá el material volado [6]. El objetivo de una voladura es buscar el resultado óptimo en la fragmentación, para lo cual se tiene en cuenta tres factores principales: cantidad, distribución y correcto confinamiento de energía.

Uno de los parámetros que se utilizan para analizar el resultado de la voladura es la granulometría, que se puede conocer de manera adecuada con el X50 (índice de fragmentación medio), el cual puede ser obtenido utilizando diferentes métodos; uno de los más conocidos, es utilizando los distintos tamaños que van ingresando a la planta de tratamiento, los cuales son separados con mallas y subprocesos. Para la predicción de la fragmentación se utilizan mayormente el modelo de Kuz-Ram, y también el KCO.

Hasta el momento no existe un método que ayude a tener una predicción exacta; sin embargo, en la última década diversos investigadores han venido trabajando en esta área realizando modelos; utilizando para ello, simples fórmulas empíricas a complejas simulaciones. En la actualidad técnicas de aprendizaje automático, permiten generar mayor optimización en los procesos de diferentes sectores [7].

En China, [8] para predecir y controlar con precisión las vibraciones de las voladuras, propuso el modelo de predicción PSO-LSSVM y el modelo de optimización MOPSO. Para ello, seleccionaron los (RMSE), el (MAE) y el índice de correlación como los indicadores de evaluación. Obteniendo como resultado que el RMSE y MAE se correlacionaron negativamente con el desempeño de los modelos, mientras que, para coeficiente de correlación, las eficiencias de PSO-LSSVM, GABP, el modelo LSSVM no optimizado y BP se compararon calculando y evaluando los indicadores de desempeño.

En EE. UU, [9] estudiaron la predicción de la distribución de la fragmentación de rocas, considerando los parámetros de diseño de voladuras, para lo que se utilizó técnicas de aprendizaje automático, también utilizaron una red neuronal artificial multicapa y modelos de regresión de vectores de soporte para vaticinar el tamaño medio de los fragmentos de rocas, los cuales podrían ser empleados para mejorar la productividad de la operación.

En Chile, [10] realizó la estimación de fragmentación del P50, para ver si se podría medrar mediante algoritmos de aprendizaje automático, donde obtuvo como mejor resultado la estimación basada en árboles de decisiones, con un ajuste del 0.73 y un RMSE de 16.21. Concluyó que el uso de estos modelos predictivos tiene mayores ventajas frente a los modelos empíricos, porque no se limita a la cantidad de datos. Por ello cuando se dispone de mayor información o esta es más representativa, los modelos entregarán predicciones más exactas.

En Lima, [7] realizó una malla de perforación y voladura controlando la fragmentación de rocas en minas open pit, utilizando método de redes neuronales artificiales, obteniendo

como resultado una reducción de la perforación en un 12.5 %; por ello, concluyó que dicho método influye en costos operacionales de perforación y voladura, con lo que se puede obtener una mayor rentabilidad en los procesos.

Por otra parte, [11] en su investigación para la mejora del tamaño de fragmentación mediante métodos de perforación y voladura de rocas, mediante el uso de técnicas como en el análisis multivariable (MVA), Kuznetsow y redes neuronales artificiales; demostró que, mediante un análisis multivariante, es factible realizar una predicción de la variabilidad granulométrica teórica generando en el método un límite de confianza del 95% logrando efectividad de su aplicación.

El problema o los desafíos que constantemente enfrentan los profesionales del sector minero con la fragmentación de roca en open pit conlleva a plantearse la pregunta ¿Cómo se puede mejorar la fragmentación de la voladura de rocas en minas open pit utilizando modelos predictivos?

La predicción de la fragmentación por voladura se hace más difícil si se enfoca desde un punto de vista técnico; más aún, si se toma en cuenta la profundización del yacimiento y los cambios de leyes. Además, se debe tomar en cuenta los esfuerzos que actúan sobre el macizo rocoso, dilución del material, elevada fragmentación y el material que se va enviar desde la mina a la planta de producción en superficie.

Actualmente, la integración de herramientas de inteligencia artificial (IA) y herramientas informáticas, permiten optimizar este proceso para lograr una mayor producción, reducción de costos y trabajar en el desarrollo de nuevos modelos y técnicas más eficientes. Es el futuro de minería inteligente (MI), por la implementación de la inteligencia artificial (AI) y softwares informáticos que está en evolución y es clave para la aplicación de técnicas y algoritmos que se desarrollan; por ello, es primordial conocer la fragmentación de la voladura y realizar modelos predictivos que, en base a la información obtenida, permitan tomar decisiones para mejorar la cadena productiva.

La presente investigación contribuye conocimientos del uso de redes neurales artificiales, para predecir la fragmentación de la voladura en rocas, manejando el lenguaje de programación Python.

El objetivo de la presente investigación es optimizar la fragmentación de la voladura de rocas en open pit mediante modelos predictivos, y tiene como objetivos específicos, determinar los valores de los coeficientes de correlación de Pearson para los parámetros de perforación y voladura, minimizar el error cuadrático medio utilizando el algoritmo Adam, comparar los valores del P80, P50 y P20 estimados con los datos reales.

## II. METODOLOGÍA

Según el enfoque de la investigación, es cuantitativo, basado en los datos reales de la mina a cielo abierto, el desarrollo utiliza recolección de datos para comprobar la hipótesis y establecer patrones de comportamiento, basado en la medición y análisis estadístico. Considerando el propósito del

estudio, es tipo aplicada, porque se centra en aplicar y buscar nuevos conocimientos para responder un problema y/o necesidad, por ende, incrementar el desarrollo social y entorno productivo [12].

Concorde al estudio, se tiene un diseño no experimental, dado que las variables no están siendo manipuladas o controladas, además es de nivel descriptivo basándose en la recolección de data, para describir las variables y analizar el comportamiento [13].

#### A. Población

La población para la investigación está compuesta por las mallas utilizadas en las operaciones de perforación y voladura en minería a cielo abierto.

#### B. Muestra

La muestra de estudio está representada por una base de datos reales, donde se utiliza una malla específica para perforación y voladura en una mina a cielo abierto.

#### C. Tamaño de muestra

Se trabajó con 47 muestras de registros de voladuras, en una mina open pit. Se utilizó el 80% de muestras para poder realizar el entrenamiento del ANN y 20% para el testeo de forma aleatoria.

#### D. Métodos e instrumentos utilizados para recopilar y analizar datos.

##### 1) Métodos de obtención de información.

Para la investigación, se empleó el método de inspección visual (observación) para analizar datos reales de una mina a cielo abierto; en base ello, se tomaron 47 muestras de registros de voladura los cuales comprenden parámetros de perforación y voladura como burden, espaciamento, altura del banco, diámetro de taladro, taco, densidad de explosivo, densidad mineral, resistencia a la compresión uniaxial, factor de potencia, unidad geológica, P80, P50 y P20.

##### 2) Instrumentos utilizados para analizar datos

Las principales herramientas son catálogos o fichas de explosivos nacionales e internacionales, manuales y datos técnicos perforación y voladura.

#### E. Uso de la Red Neuronal Artificial (ANN)

Las ANN están formadas por varios componentes de procesamiento simples que se encuentran interconectados, conocidos como neuronas o nodos [14]. Cada nodo en la red neuronal recibe un carácter de entrada que contiene información proveniente de otros nodos o estímulos externos. Luego, procesa este carácter localmente mediante una función de activación o transferencia, lo que da lugar a un carácter de salida. Este carácter de salida es enviado a otros nodos dentro de la red o a salidas externas para continuar el proceso de procesamiento de información señalada en la Fig. 1. Aunque

una neurona individual puede parecer muy simple, la verdadera potencia reside en la interconexión de múltiples neuronas para construir una red neuronal [15].




Fig. 1 El modelo de red neuronal artificial (ANN).

También cabe mencionar que la ventaja principal de la ANN, es la capacidad que tiene para ingresar efectos e interacciones que no sean lineales entre las variables del modelo, y todo esto lo hace sin tener la necesidad de incluirlas a priori, también es imprescindible su capacidad para sintetizar significados de datos complicados o imprecisos [16]. En la actualidad, existe bastante interés en obtener modelos predictivos adecuados en las minas. Las Redes Neuronales Artificiales están ganando cada vez más popularidad como una opción viable para abordar diversos problemas y desafíos. En el presente estudio se utilizó el tipo más común de ANN, la cual fue entrenada con el algoritmo Adam.

#### F. Diseño de una Red Neuronal para el Caso de Estudio.

Al diseñar una red neuronal, es esencial tener en cuenta los hyperparameters, que son parámetros ajustables que juegan un papel crítico en la configuración de la red. Estos parámetros son fundamentales para obtener una estimación precisa y efectiva de los resultados de la investigación [17]. Para ello, es necesario considerar la activación de la función, batch size, foomch, lost funtion, learning rate, optimizer y layers (cantidad de capas).

Para asegurar un diseño efectivo para la ANN es necesario identificar la configuración óptima de los elementos que conforman su arquitectura.

En el presente estudio, para determinar la arquitectura óptima, se consideró dos aspectos clave: la cantidad de capas y la cantidad de neuronas presentes en cada una de las capas. También fue fundamental establecer los pesos iniciales y seleccionar la función de activación. Además, se consideró investigaciones previas para identificar el algoritmo de entrenamiento más adecuado para abordar con éxito el problema en cuestión. Estos factores combinados, permitieron encontrar la configuración más efectiva para la ANN.

##### 1) Número de capas

En el estudio, se optó por utilizar tres capas en la arquitectura de la Red Neuronal Artificial, ya que esta configuración

específica se adapta de manera particular al problema que se está abordando.

### 2) Cantidad de neuronas por capa

La arquitectura de la ANN está compuesta por trece neuronas en la capa oculta y tres neuronas en la capa de salida.

### 3) Inicialización de Peso

En cada neurona, se asignan pesos individuales (W) que son distintos para cada conexión. Además, se incorpora un parámetro "b", que es compartido por todas las neuronas que se encuentran en una misma capa.

Al comenzar el entrenamiento de la red, los pesos se inicializan de forma aleatoria, y es crucial que estos valores iniciales sean lo suficientemente pequeños y cercanos al origen. Esta medida se adopta para garantizar que la función de activación opere en su régimen lineal, lo que facilita el aprendizaje inicial de la ANN.

### 4) Función de activación de cada capa

Para lograr esto, se aplicó la función sigmoide. La función sigmoide tiene la propiedad de simetría [18] y está definida en (1). Utilizar esta función como activación de cada capa permite beneficiarse de sus características para el procesamiento de la información dentro de la red neuronal.

$$f(x) = 1/(1+\exp(-x)) \quad (1)$$

Dónde:

f: Función sigmoidea

x: Variable

La función sigmoide presenta una forma similar a una "S" y su rango de salida se encuentra entre 0 y 1. Esta función es comúnmente empleada en problemas de clasificación binaria, donde el resultado de la red neuronal puede tomar valores de 0 o 1, lo que facilita la tarea de asignar las clases correspondientes a las entradas [19].




Fig. 2 Función sigmoidea

### 5) Set de datos

En primer lugar, está el set de entrenamiento, el cual es utilizado para que la red neuronal pueda aprender y reconocer patrones en los datos. El código utilizado es el siguiente:

```
x_train
```

```
y_train
```

En segundo lugar, está el set de validación, se compone de datos distintos a los del conjunto de entrenamiento y se utiliza para evaluar cómo la red procesa nuevos datos. Este set es útil para determinar los mejores parámetros de la red neuronal. A continuación, se presenta el código utilizado:

```
x_val
```

```
y_val
```

Finalmente, el test set, el cual se emplea para concluir el proceso de entrenamiento de la red neuronal. Además, permite evaluar el rendimiento de la red después de haber sido entrenada. El código que se utiliza para esta fase de evaluación es:

```
x_test
```

```
y_test
```

### G. Algoritmo de entrenamiento ADAM

Para lograr la validación y el entrenamiento de la Red Neuronal Artificial diseñada, se experimentaron diversos algoritmos de descenso con el objetivo de identificar aquellos que llevaran a una convergencia óptima para la ANN. Según [20], los algoritmos de descenso de gradiente están ganando cada vez más reconocimiento como métodos eficaces para llevar a cabo la optimización de redes neuronales.

El algoritmo Adam es el resultado de una técnica de optimización estocástica. Su capacidad para acelerar el proceso de optimización se logra calculando un tamaño de paso adecuado para cada uno de los parámetros de entrada, lo que contribuye significativamente a mejorar la eficiencia del entrenamiento [21]. En el algoritmo Adam, cada tamaño de paso se ajusta automáticamente durante el proceso de entrenamiento a medida que se van encontrando los gradientes para los inputs [22]. Este algoritmo considera tres parámetros [23]:

$\alpha$ : Tasa de aprendizaje. Valores grades, dan un aprendizaje rápido, no permitiendo que se actualice la tasa en el proceso, en cambio los valores pequeños hacen que el proceso de aprendizaje sea más lento en el entrenamiento. Se considera típicamente como 0.001.

$\beta_1$ : Tasa de caída en el primer momento de la estimación. Valor común de 0.9.

$\beta_2$ : Tasa de caída de la estimación de segundo orden. Valor común de 0.999.

El algoritmo Adam comienza inicializando los parámetros  $\theta$  (W y b) con valores aleatorios, así como la tasa de aprendizaje (tamaño de paso) y la tasa de decaimiento. Una configuración efectiva para este algoritmo es establecer alfa como 0.001, beta uno como 0.9 y beta dos como 0.999 [22].

Con base a este conocimiento, se llevó a cabo diversas pruebas utilizando el algoritmo mencionado para determinar los resultados más favorables. Después de un análisis exhaustivo, se tomó la decisión de seleccionar el algoritmo Adam para la ANN.

El learning rate o tasa de aprendizaje determina el tamaño de los pasos que toma el algoritmo de optimización. Si esta tasa es muy pequeña, puede llevar a que la red quede atrapada en mínimos locales y los parámetros "W" y "b" no se ajusten adecuadamente, lo que ralentiza el proceso de optimización. Por otro lado, si el valor del learning rate es muy alto, el aprendizaje será más rápido; pero, existe el riesgo de no alcanzar el mínimo global y la red podría no converger de manera efectiva.

La función de pérdida (lost function) representa la medida de la adecuación o el rendimiento de la ANN. Cuando el valor de la función de pérdida es alto, indica que el desempeño del modelo es inadecuado; es decir, está cometiendo errores significativos. Por el contrario, un valor bajo de la función de pérdida indica que el rendimiento de la red es adecuado, lo que significa que está haciendo predicciones precisas y se ajusta bien a los datos de entrenamiento [20]; por lo tanto, esta es la función que buscaremos optimizar en el diseño de la ANN.

En el presente estudio, se llevó a cabo una actualización iterativa de los valores de "W" y "b" para un total de 600 ciclos. En cada ciclo los datos que se considera para el entrenamiento van a pasar por la ANN para que la red aprenda de estos datos [24].

El error cuadrático medio (ECM) se utiliza para estimar la discrepancia entre los resultados estimados y los datos reales en una base de datos [25]. El ECM proporciona una medida promedio del error cuadrático entre los puntos y la línea de regresión. ECM es una métrica siempre positiva que refleja la precisión de las predicciones. Cuando el error en las estimaciones disminuye, el ECM también lo hace. En consecuencia, a medida que los valores estimados se acercan más a los valores reales, el ECM disminuye, proporcionando una medida más pequeña de la discrepancia entre ambos conjuntos de datos [26]. La manera de calcularlo se logra empleando (2).

$$ECM = \sum(O_i - E_i)^2/n \quad (2)$$

Donde:

$O_i$ : Valores observados

$E_i$ : Valores estimados

$\sum$ : Letra griega (sigma), representa la «sumatoria».

n: Cantidad de observaciones.

#### H. Diseño y Experimentación de ANN

Los parámetros de entrada se obtuvieron de [27], el cual tiene 47 muestras de registros de voladuras, en una mina open pit. Esta data cuenta con los parámetros geomecánicos de macizo rocoso, del diseño para malla específica sobre perforación y voladura, también con propiedades físicas y químicas del explosivo. Para la programación se empleó Python 3.11.4, y se tomaron 37 muestras para poder realizar el entrenamiento del ANN y 9 para el testeo.

Se consideró como parámetros de input, a la densidad de mineral, densidad de explosivo, burden, espaciamento, kilogramos de explosivo cargado, factor de carga, taco (stemming) y unidad geotécnica. Para el output se consideró el P80, P50 y P20. El diámetro de perforación, banco y sobreperforación no se consideró porque permanecen constantes en la base de datos.

Obtenido los datos de input, donde se consideran parámetros del diseño para malla específica sobre perforación y voladura, explosivos y parámetros geomecánicos del macizo rocoso, se diseñó la ANN, evitando su acumulación para que pueda alcanzar el aprendizaje esperado, determinándose la cantidad de capas y neuronas para que funcione adecuadamente. En la Fig. 3 se exhibe el esquema del diseño de la ANN con una capa oculta, así como los input y output a obtener.

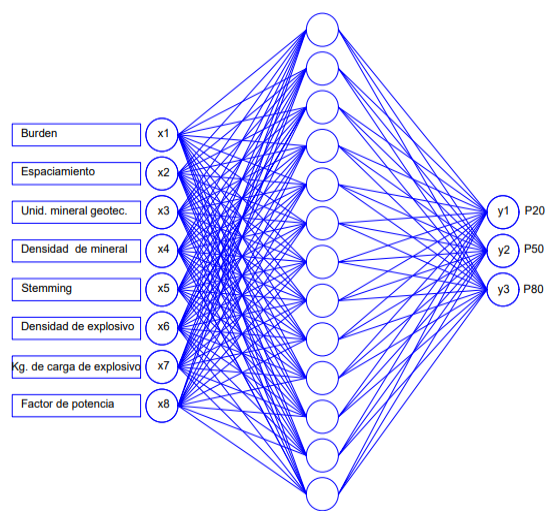


Fig. 3 Diagrama del diseño ANN

Cybenko [28], menciona que para hallar la cantidad de capas ocultas se puede utilizar cualquier función continua para aproximarse de manera constante mediante modelos de redes neurales con una capa oculta. Se requiere hallar las capas y neuronas ocultas para no afectar la capacidad al generar el modelo, [29] menciona que estas influyen en la precisión cuando se calcula un nuevo ejemplo. La ANN, tendrá una capa oculta, mostrada en la Fig. 3. Es factible calcular el número de neuronas en una capa oculta mediante fórmulas empíricas. Hecht-Nielsen [30], considera  $2n + 1$  ("n" cantidad de neuronas de input) como la cantidad máxima de neuronas en una capa oculta. Por ejemplo, si  $n = 8$ , la cantidad de neuronas que se requiere será menor o igual a 17. Consideran la cuantía de neuronas para una capa oculta.

Por otra parte, [31] consideran que la cuantía de neuronas para una capa oculta satisface (3):

$$\sum_{i=0}^n C_N^i > K \quad (3)$$

Donde:

$$\sum_{i=0}^n C_N^i = N! / (i! (N - i)!) > K \quad (4)$$

$n$ : cantidad de parámetros de input

$K$ : cantidad de conjunto de datos usados

$N$ : cantidad de neuronas ocultas

Para el caso de estudio, se consideró “ $n$ ” = 8,  $K$  = 47 de donde se obtiene  $N > 8$ ; por lo tanto, el  $N$  será mayor o igual a 9 y menor o igual a 17.

El resultado de  $N$ , permitió hallar y establecer la adecuada forma del ANN, considerando el error cuadrático medio y coeficiente de correlación, de los valores reales y predichos.

El modelo obtenido, muestra resultados moderadamente fiables; pero, se debe seguir realizando un adecuado monitoreo en los registros de voladura, para fortalecer los datos de entrada y lograr conseguir un modelo con una mejor predicción.

### III. RESULTADOS Y DISCUSIÓN

#### A. Determinar valores de los coeficientes de correlación de Pearson.

Los valores de correlación varían entre [-1. + 1]. La variable es resultado de una transformación lineal de otra cuando el coeficiente es igual o cercano a 1 o -1. La relación es directamente proporcional cuando se acerca a 1, e inversa cuando se acerca a -1. Cuando el coeficiente es 0 se aproxima a 0, no hay relación lineal [32].

En la Fig. 4, se muestra la matriz de correlación entre los parámetros de input y output del ANN, esta permitió saber el resultado del coeficiente de correlación de Pearson, el cual permite conocer la relación lineal de las variables. Tal como se observa existe correlación negativa para la densidad del explosivo, burden, espaciamiento, kilogramos de explosivo cargados, los cuales se aproximan a -1; por ello, influyen de manera inversa en los resultados de fragmentación de P80, P50 y P20.

Por otra parte, existe correlación positiva en la unidad mineral geotécnica (GU), factor de carga, densidad de mineral y stemming (taco), por lo cual influyen directamente en los resultados de fragmentación. Se observa que el parámetro GU, influye más en el proceso de perforación y voladura al analizar los resultados de P80, P50, P20.




Fig. 4 Matriz de correlación de parámetros (input-output)

#### B. Minimizar el error cuadrático medio utilizando Algoritmo Adam.

Diseñó la arquitectura del ANN, comenzó su etapa de entrenamiento y su validación. Con los resultados obtenidos, se hizo el entrenamiento, y se aplicó el algoritmo Adam con una tasa de aprendizaje de 0.01 y 600 ciclos, para minimizar el error cuadrático medio con los resultados de entrenamiento y valores de “ $n$ ”, de acuerdo con la representación gráfica presentada en la Fig. 5.

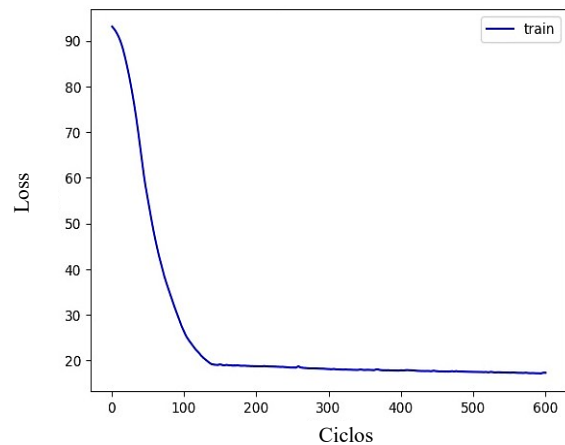


Fig. 5 Error cuadrático medio de la raíz vs número de ciclos.

Cuando se analizó la Fig. 5, se verificó que con “ $n$ ” igual a 13 se obtiene una raíz cuadrática media con más bajo error medio con un valor de 16.5. Por ello, se procedió a utilizar “ $n$ ” igual a 13 en la neurona ANN para predecir P80, P50, P20.

#### C. Comparar los valores del P80, P50 y P20 estimados con los datos reales.


La tabla I, muestra los resultados que se obtuvieron en el testeó con las 9 muestras, las cuales se eligieron de forma aleatoria de las 37 muestras escogidas para realizar el

entrenamiento de la ANN.

TABLA I  
DATOS UTILIZADOS PARA EL TESTEO

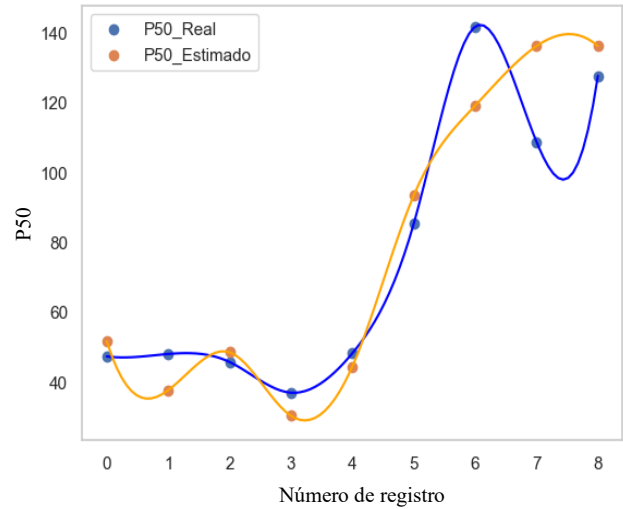
| Muestras del testeo | Real   |        |       | Estimado |        |       |
|---------------------|--------|--------|-------|----------|--------|-------|
|                     | P80    | P50    | P20   | P80      | P50    | P20   |
| 0                   | 83.40  | 47.20  | 12.30 | 89.55    | 50.19  | 9.82  |
| 3                   | 88.30  | 47.90  | 9.76  | 64.57    | 36.95  | 6.35  |
| 9                   | 80.60  | 45.60  | 8.28  | 85.81    | 48.83  | 9.12  |
| 19                  | 60.90  | 36.80  | 6.54  | 50.16    | 29.80  | 4.30  |
| 21                  | 84.00  | 48.10  | 8.19  | 75.37    | 43.16  | 7.79  |
| 36                  | 178.20 | 85.20  | 26.10 | 176.66   | 97.49  | 29.75 |
| 39                  | 272.90 | 141.70 | 24.10 | 230.38   | 126.73 | 37.40 |
| 44                  | 220.90 | 108.70 | 31.40 | 261.25   | 143.46 | 44.56 |
| 46                  | 241.20 | 127.60 | 38.50 | 261.25   | 143.46 | 44.56 |

En la Fig. 6 se observa la distribución de los datos reales y estimados del P80, en función de la cantidad de muestras utilizadas para el testeo, en la cual se estimó que las predicciones se ajustan un 91% a los valores reales en la mayoría de los registros, lo que indica que la red neuronal aprendió a estimar de manera aceptable el P80.



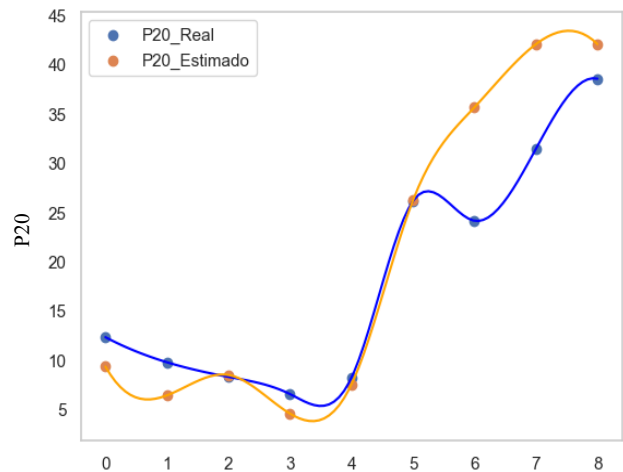
Número de registro  
Fig. 6 P80 real vs P80 estimado

Para P50 y P20, el ajuste disminuye, porque la predicción se enfoca más en el P80. En la Fig. 7 se observa la distribución de los datos reales y estimados del P50, en función de la cantidad de muestras utilizadas para el testeo. Se verificó que las predicciones se ajustan un 84 % a los valores reales en la mayoría de los registros, lo que indica que la red neuronal puede estimar de manera aceptable el P50.



Número de registro  
Fig. 7 P50 real vs P50 estimado

La Fig. 8 muestra la distribución de los datos reales y estimados del P20, en función de la cantidad de muestras utilizadas para el testeo. Se verificó que las predicciones se ajustan un 62 % a los valores reales en la mayoría de los registros, lo que indica que la red neuronal puede a estimar de manera moderada el P20.



Número de registro  
Fig. 8 P20 real vs P20 estimado

La tabla II, contiene la correlación entre los resultados obtenidos mediante el modelo ANN y el real. Se observa mayor correlación en los resultados del P80, el cual presenta un  $R^2 = 0.91$ . Para el P20 y P50, se obtuvo una correlación  $R^2 = 0.62$  y  $R^2 = 0.84$  respectivamente. Estos coeficientes de correlación disminuyen porque los inputs se enfocan mayormente en el P80. Además, se puede apreciar que los restantes valores de los parámetros estadísticos de la ANN se acercan a los reales P80, P50 y P20.

TABLA II  
PARÁMETROS ESTADÍSTICOS DE LOS DATOS REALES Y ESTIMADOS

| Parámetros estadísticos        | Real  |       |        | Estimado |       |        |
|--------------------------------|-------|-------|--------|----------|-------|--------|
|                                | P20   | P50   | P80    | P20      | P50   | P80    |
| Media (mm)                     | 18.35 | 76.53 | 145.60 | 25.46    | 89.88 | 163.58 |
| Desviación. Estad.             | 11.18 | 37.99 | 77.76  | 17.32    | 47.26 | 87.11  |
| Coefficiente de variación      | 0.61  | 0.50  | 0.53   | 0.68     | 0.53  | 0.53   |
| Coefficiente de correlación R2 |       |       |        | 0.62     | 0.84  | 0.91   |

Los coeficientes de correlación R2 obtenidos, son aceptables y podemos controlar la fragmentación de roca en la voladura, para mejorar los rendimientos y costos en los demás procesos mineros (carguío, transporte, trituración y molienda). Sin embargo, para obtener un modelo más preciso, se debe realizar la estimación utilizando diferentes algoritmos de entrenamiento y considerar parámetros de input relevantes.

Finalmente, se comprobó el desempeño de la ANN en la estimación de los valores del P80, P50 y P20, para lo cual se consideró diferentes parámetros de entrada, para posteriormente analizar los resultados estimados tal como se observa en la Fig.9




Fig. 9 Predicciones P80, P50 y P20

#### IV. CONCLUSIONES

Se logró el objetivo principal de realizar la optimización en la fragmentación por voladura de rocas en open pit mediante modelos predictivos.

Se determinó la correlación entre los parámetros de perforación y voladura, donde se obtuvo una correlación

negativa para la densidad del explosivo, burden, espaciamento, kilogramos de explosivo cargados, los cuales se aproximan a -1; por ello, influyen de manera inversa en los resultados de fragmentación de P80, P50 y P20. Asimismo, se encontró una correlación positiva en la unidad mineral geotécnica (GU), factor de carga, densidad de mineral y taco; por lo cual, influyen directamente en los resultados de fragmentación. El parámetro GU, influye más en el proceso de perforación y voladura al analizar los resultados de P80, P50, P20.

Se minimizó el error cuadrático medio, utilizando el algoritmo de entrenamiento Adam, aplicando una tasa de aprendizaje de 0.01, 600 ciclos y un "n" igual a 13 en la ANN, obteniendo un ECM de 16.5.

Se comparó los datos reales con los estimados, donde se obtuvo una mayor correlación en los resultados de P80, el cual presentó un coeficiente de correlación R2 igual a 0.91. Para el P20 y P50, se obtuvo un R2 de 0.62 y 0.84 respectivamente. Estos coeficientes de correlación disminuyen porque los inputs se enfocan más en el P80, además, se demostró que los demás valores de los parámetros estadísticos estimados se acercan a los reales del P80, P50 y P20.

#### REFERENCIAS

- [1] N. Escalante, «Técnicas de Perforación y Voladura,» *Promine*, 2022.
- [2] A. Majid, L. Gholamreza, Y. Alireza, G. Mohammada y B, «Blastability evaluation for rock mass fragmentation in Iran central iron ore mines,» *Int. J. Rock Mech. Min. Sci.*, 2015.
- [3] B. Cebrían, M. Rocha, B. Morales y L. Castañón, «Mine to Mill at ultra hard high grade Gold Mine fragmentation vs dilution final MR BC,» 2017.
- [4] B. A. Kansake, V. Temeng y B. Afum, «Comparative Analysis of Rock Fragmentation Models - A Case Study,» *UMaT Biennial International Mining and Mineral Conference*, 2016.
- [5] G. Ballantyne, «Quantifying the additional energy consumed by ancillary equipment and embodied in grinding media in comminution circuits,» *Canada*, 2019.
- [6] S. Esen, «Modelado de fragmentación y los efectos de la fragmentación de ROM en los circuitos de trituración,» 2013.
- [7] Y. Idrogo, «Machine learning aplicado al control de la fragmentación de rocas en la voladura de minas a tajo abierto,» *Lima, Perú*, 2022.
- [8] J. Guo, P. Zhao y P. Li, «Predicción y Optimización de la Vibración del Suelo Inducida por Voladuras en Minas a Cielo Abierto Utilizando Algoritmos Inteligentes,» *Ciencia aplicada*, 2023.
- [9] R. Amoako, A. Jha y S. Zhong, «Predicción de fragmentación de rocas utilizando una red neuronal artificial y un enfoque híbrido de regresión de vectores de soporte,» *Minería*, 2022.
- [10] F. Rojas, «Estimación de la fragmentación producto de la tronadura de rocas en minería a cielo abierto utilizando modelos predictivos y algoritmos de regresión,» *Chile*, 2021.
- [11] E. L. Rojas Linares, «Enfoque predictivo para la optimización del tamaño de fragmentación en base a técnicas de perforación y voladura de rocas,» *Lima, Perú*, 2021.
- [12] Duoc.cl., «Definición y propósito de la Investigación Aplicada,» *Duoc.cl*, 2023.
- [13] M. Martínez, «Diseño de investigación,» *Universidad Nacional de Córdoba*, 2013.



- [14] P. Stephanny, «Qué son y cómo funcionan las Redes Neuronales Artificiales,» *Infobae*, 2023.
- [15] F. Pinheiro Azevedo, «¿Qué son las redes neuronales?,» *Tomorrow.bio*, 2023.
- [16] W. A. Castañeda Sánchez, B. R. Polo Escobar y F. Vega Huincho, «Redes neuronales artificiales: una medición de aprendizajes de pronósticos como demanda potencial,» vol. 27, 2022, pp. 51-60.
- [17] M. Sotaquirá, «Parámetros e hiperparámetros en el Machine Learning,» 2023.
- [18] D. Calvo, «Función de activación - Redes neuronales,» 2018.
- [19] P. Huet, «Qué son las redes neuronales y sus aplicaciones,» 2023.
- [20] F. Sancho Caparrini, «Redes Neuronales: una visión superficial,» 2022.
- [21] D. Kingma y J. Lei Ba, «Adam: un método para la optimización estocástica,» 2014.
- [22] M. Pauner Aicart, «Red neuronal para la elección de los parámetros de compresión óptimos,» 2022.
- [23] A. Rojano Aguilar, R. Salazar Moreno, L. Miranda y W. Ojeda, «Algoritmo Adam en la inteligencia artificial,» 2021.
- [24] V. Rodríguez, «Conceptos básicos sobre redes neuronales,» 2018.
- [25] P. Sáez, «Error Cuadrático Medio explicado,» *De datos a Decisiones*, 2023.
- [26] D. Yonghe, «Perfectively Deducing Bessel Mean Square Error Formula,» *The Open Civil Engineering Journal*, vol. 9, nº 1, pp. 423-425, 2015.
- [27] J. Silva, J. Amaya y F. Basso, «Development of a predictive model of fragmentation using drilling and blasting data in open pit mining,» *Journal of the Southern African Institute of Mining*, vol. 117, nº 11, pp. 1087-1096, 2017.
- [28] G. Cybenko, «Aproximación por superposiciones de una función sigmoideal,» *Matemáticas, Sistema de señales de control*, pp. 303-314, 1989.
- [29] A. Garcés Jiménez, J. Castillo Sequera, A. Del Corte Valiente, J. Gómez Pulido y E. González Seco, «Análisis de arquitecturas de redes neuronales artificiales para el modelado de sistemas de iluminación inteligente para el ahorro energético,» pp. 119881-119891, 2019.
- [30] R. Hecht Nielsen, «Redes de contrapropagación. aplicación Optar,» *Aplicación Optar*, pp. 4979-4984, 1987.
- [31] Z. Ge y Z. Sun, «Teoría de redes neuronales y aplicación MATLAB R2007,» *Editorial de la Industria Electrónica*, pp. 108-122, 2007.
- [32] C. Ortega, «¿Qué es el coeficiente de correlación de Pearson?,» *QuestionPro*, 2019.