

**“DESARROLLO DE UNA RED NEURONAL  
ARTIFICIAL (ANN) PARA LA PREDICCIÓN DEL  
ÍNDICE DE FRAGMENTACIÓN MEDIO ( $X_{50}$ ) EN LAS  
OPERACIONES DE VOLADURA EN MINERÍA  
SUPERFICIAL 2024”**

Tesis para optar al título profesional de:

**Ingeniero de Minas**

**Autores:**

José Mercedes Ferrer Pajares  
Máximo Antonio Velásquez Alcalde

**Asesor:**

Dr. Ing. Miguel Ricardo Portilla Castañeda  
<https://orcid.org/0000-0002-3676-7137>

Cajamarca - Perú

2024

## JURADO EVALUADOR

Jurado 1 Presidente(a)	<b>Sheyla Yuliana Cornejo Rodriguez</b>
	Nombre y Apellidos

Jurado 2	<b>Eduardo Manuel Noriega Vidal</b>
	Nombre y Apellidos

Jurado 3	<b>MIGUEL RICARDO PORTILLA CASTAÑEDA</b>
	Nombre y Apellidos

## INFORME DE SIMILITUD

### Desarrollo de una Red Neuronal Artificial (ANN) Para la Predicción del Índice de Fragmentación Medio ( $X_{50}$ ) en las Operaciones de Voladura en Minería Superficial 2024

#### INFORME DE ORIGINALIDAD

<b>11</b> %	<b>11</b> %	<b>7</b> %	<b>0</b> %
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

#### FUENTES PRIMARIAS

<b>1</b>	<a href="https://tesis.ucsm.edu.pe">tesis.ucsm.edu.pe</a> Fuente de Internet	<b>7</b> %
<b>2</b>	<a href="https://hdl.handle.net">hdl.handle.net</a> Fuente de Internet	<b>1</b> %
<b>3</b>	José Garrigues Baixauli. "Implementación de algoritmos de redes neuronales artificiales de tipo Fuzzy Artmap y Multilayer Feed Forward con dispositivos electrónicos programables en sistemas de lenguas electrónicas para la clasificación de muestras y determinación de parámetros fisicoquímicos", Universitat Politecnica de Valencia, 2013 Publicación	<b>1</b> %
<b>4</b>	<a href="https://oa.upm.es">oa.upm.es</a> Fuente de Internet	<b>1</b> %
<b>5</b>	<a href="https://core.ac.uk">core.ac.uk</a> Fuente de Internet	<b>1</b> %

[es.scribd.com](https://es.scribd.com)

## DEDICATORIA

Dedico este trabajo de investigación en primer lugar a Dios y a toda mi familia y en especial a mi hijo Rodrigo, quienes me han brindado todo su apoyo y soporte durante mi vida universitaria, ellos han sido mi motor, me han impulsado a seguir y nunca desistir pese a que en el camino se han presentado diversos obstáculos y dificultades, siempre espero contar con su constante apoyo.

José M. Ferrer Pajares.

Dedico esta investigación a Dios y mi familia porque gracias a su soporte, amor e inspiración constantes, motivaron en mí, la idea de ser mejor, seguir adelante y trascender en la vida pese a sus dificultades.

Máximo Antonio Velásquez Alcalde

## **AGRADECIMIENTO**

Un agradecimiento especial a Dios, a nuestro asesor, a la universidad, a sus docentes quienes contribuyeron con mi desarrollo en este largo camino profesional de mi carrera, compartiendo todas sus experiencias en las diferentes disciplinas y especialidades y compañero de estudio Máximo, gracias a quien pudimos afinar la idea de investigación y encontrar la motivación para continuar con este proyecto innovador y revolucionario en términos de digitalización en operaciones mineras.

José M. Ferrer Pajares.

Un agradecimiento especial a nuestros asesores, universidad, sus docentes y compañeros de estudio, por sus aportes para el desarrollo de esta idea de investigación y aliento para continuar con este reto en aras de la digitalización de las operaciones mineras.

Esperamos aportar nuevos conocimientos y herramientas para futuras investigaciones y toma de decisiones más eficientes, informadas y analíticas.

Máximo Antonio Velásquez Alcalde.

**TABLA DE CONTENIDO**

JURADO EVALUADOR	2
INFORME DE SIMILITUD	3
DEDICATORIA	4
AGRADECIMIENTO	5
TABLA DE CONTENIDO	6
ÍNDICE DE TABLAS	7
ÍNDICE DE FIGURAS	8
RESUMEN	11
CAPÍTULO I: INTRODUCCIÓN	12
CAPÍTULO II: METODOLOGÍA	19
CAPÍTULO III: RESULTADOS	49
CAPÍTULO IV: DISCUSIÓN	64
CONCLUSIONES	68
RECOMENDACIONES	69
REFERENCIAS	70
ANEXOS	72

## Índice de tablas

**Tabla 1:** *Código denominación de predictores*..... 23

**Tabla 2:** *Datos usados como predictores en la (ANN) para las operaciones de voladura*  
..... 51

## Índice de figuras

<b>Figura 1:</b> <i>Interfaz de Matlab R2017b para el Desarrollo de la Red Neuronal Artificial (ANN) ..</i>	21
<b>Figura 2:</b> <i>Código de ingreso de datos a Matlab R2017b.....</i>	22
<b>Figura 3:</b> <i>Código de programación para la visualización de los histogramas distribución de predictores.....</i>	23
<b>Figura 4:</b> <i>Histogramas de distribución de los datos usados como predictores para el entrenamiento de la ANN.....</i>	23
<b>Figura 5:</b> <i>Código de programación para la normalización de los datos de los predictores y la generación de los nuevos Histogramas de Frecuencia de los datos normalizados.....</i>	25
<b>Figura 6:</b> <i>Histogramas de distribución de los datos normalizados .....</i>	25
<b>Figura 7:</b> <i>Código de programación para determinar la correlación entre los predictores y el resultado esperado (<math>X_{50Real}</math>).....</i>	26
<b>Figura 8:</b> <i>Gráficas de correlación entre los predictores y el resultado esperado (<math>X_{50Real}</math>).....</i>	27
<b>Figura 9:</b> <i>Código de programación para determinar la correlación entre los predictores normalizados y el resultado esperado (<math>X_{50Real}</math>).....</i>	28
<b>Figura 10:</b> <i>Gráficas de correlación entre los predictores normalizados y el resultado esperado (<math>X_{50Real}</math>).....</i>	29
<b>Figura 11:</b> <i>Código de programación para diseñar la arquitectura de la ANN, seleccionar el número de capas ocultas y determinar los porcentajes de datos a usar para su entrenamiento, validación y prueba.....</i>	31
<b>Figura 12:</b> <i>Reporte del entrenamiento de la ANN con 14 neuronas en la capa oculta escogidas de forma aleatoria .....</i>	31

**Figura 13:** *Graficas Generadas en el entrenamiento de la ANN con 14 neuronas en la capa oculta* ..... 32

**Figura 14:** *Códigos de programación para determinar el RMSE y evaluar el rendimiento del entrenamiento de la ANN*..... 35

**Figura 15:** *RMSE del entrenamiento, validación y prueba de la ANN respectivamente* ..... 35

**Figura 16:** *Códigos de programación para entrenar a la ANN desde 1 hasta 70 neuronas en la capa oculta y determinación del RMSE*..... 37

**Figura 17:** *Reporte del entrenamiento de la ANN con 70 neuronas en la capa oculta como último entrenamiento de la serie de entrenamientos de 1 a 70 neuronas en la capa oculta*..... 38

**Figura 18:***Graficas Generadas en el entrenamiento de la ANN con 70 neuronas en la capa oculta como último entrenamiento de la serie de entrenamientos desde 1 a 70 neuronas*..... 39

**Figura 19:** *RMSE del entrenamiento, validación y prueba de la ANN con 70 neuronas en la capa oculta en la serie de entrenamientos desde 1 a 70 neuronas*..... 41

**Figura 20:** *Códigos de programación para generar las curvas del RMSE del entrenamiento, validación y prueba de la ANN en la serie de entrenamientos desde 1 a 70 neuronas en la capa oculta*..... 41

**Figura 21:** *Gráfico de los 70 RMSE del entrenamiento (data 1), validación (data 2) y prueba (data 3) para determinar el valor más bajo del RMSE de la curva de validación (x) para determinar el número óptimo de neuronas de la ANN*..... 42

**Figura 22 :** *Códigos de programación para entrenar a la ANN con el número óptimo de neuronas (22) en la capa oculta*..... 43

**Figura 23:** Reporte del entrenamiento de la ANN con 22 neuronas en la capa oculta como número óptimo de neuronas para la mejor predicción del  $X_{50}$  Teórico. .... 43

**Figura 24:** Graficas Generadas en el entrenamiento de la ANN con 22 neuronas en la capa oculta como número óptimo de neuronas. .... 44

**Figura 25:** Códigos de programación para determinar el RMSE y evaluar el rendimiento del entrenamiento de la ANN con el número óptimo de neuronas (22). .... 46

**Figura 26:** RMSE del entrenamiento, validación y prueba de la ANN con número óptimo de neuronas (22) respectivamente. .... 46

**Figura 27:** Códigos de programación para la visualización de la predicción de la ANN. .... 49

**Figura 28:** Gráfica de predicción de las neuronas en la capa oculta de la ANN en los procesos de entrenamiento (data 1), validación (data 2) y prueba (data 3) ..... 50

**Figura 29:** Resultados de ANOVA unidireccional ..... 54

**Figura 30:** Resumen del modelo ..... 55

**Figura 31:** Análisis de las Medias, desviación estándar e Intervalos de Confianza ..... 55

**Figura 32:** Prueba de comparación usada: Parejas de Tukey..... 56

**Figura 33:** Gráfico de la Diferencia de Medias ..... 57

**Figura 34:** Intervalos de Confianza al 95% del Nivel de Confianza ..... 58

**Figura 35:** Gráfico de Valores Individuales ..... 59

**Figura 36:** Diagrama de caja Bigotes ..... 60

**Figura 37:** Grafica de residuales o tres en uno..... 61

## RESUMEN

El presente trabajo de investigación emplea una Red Neuronal Artificial (ANN) que permite predecir el Índice Medio de Fragmentación Teórico ( $X_{50TEÓRICO}$ ), tiene como objetivo determinar la correlación de estos datos con los obtenidos en las mediciones hechas en las pilas de residuos de voladura ( $X_{50REAL}$ ) producto de 90 procesos de voladura, con un diseño no experimental de corte longitudinal, con una población de todas las operaciones de voladura y una muestra de 90 operaciones de voladura. Teniendo como resultados que los datos usados como predictores, presentan información de los parámetros del diseño de voladura, del módulo de elasticidad y del tamaño del macizo in-situ, siendo el primer grupo de datos considerado como parámetros controlables y los dos últimos como parámetros incontrolables en los procesos de perforación y voladura. La estadística descriptiva, presentará además el ANOVA usando Minitab 19 que nos permitirá entender la correlación de los parámetros usados como predictores en relación con el parámetro de salida de la ANN, mismos que serían los parámetros a controlar en los procesos de perforación y voladura. Concluyendo que el análisis de la correlación existente entre los datos predecidos y los reales permiten determinar la eficiencia de la ANN como modelo predictivo y la significancia que esto representa para la toma de decisiones que permitan obtener tamaños de roca adecuados que eviten retrabajos y sobre costos en los procesos mineros.

**PALABRAS CLAVES:** Red Neuronal Artificial, Índice de Fragmentación Medio Teórico ( $X_{50TEÓRICO}$ ), Índice de Fragmentación Medio Real ( $X_{50REAL}$ ), Voladura.

## CAPÍTULO I: INTRODUCCIÓN

### Realidad problemática

Las operaciones de perforación y voladura son la parte fundamental del proceso minero para optimizar el resto de sub procesos mineros y conseguir así la reducción de gastos por demasiado trabajo o sobre costos generados en los procesos de molienda o flotación, así mismo, se ha visto en diversas operaciones mineras un gran consumo de energía eléctrica e hidráulica que representa un alto costo en la operación (Vargas, 2020). En este marco de referencia, se debe obtener tamaños de roca adecuados en los procesos de perforación y voladura con tamaños ideales que vuelva más eficiente el proceso de conminución, se ha vuelto un aspecto crucial de análisis, mismo que incluye el desarrollo de tecnologías que nos permitan predecir con ajustes que hacer para obtener estos resultados de manera anticipada. Es por ello, que la industria minera de Perú en el año 2023, enfoco sus esfuerzos hacia la digitalización de sus operaciones y la aplicación de la Inteligencia Artificial (IA) la cual emerge como un elemento clave para potenciar el desarrollo de este sector (Suzuki & Morales, 2021).

Según Barton (2022), menciona que, las Redes Neuronales Artificiales (ANN) son una de las tecnologías de Inteligencia Artificial, la cual muestra una gran capacidad de predicción, gracias a sus procesos de sinapsis y el uso de algoritmos que permiten no solo entrenar a esta ANN, sino que además validan y prueban estos entrenamientos antes de generar los modelos predictivos. Además, (Maestre 2023), señala que, las ANN corresponden su capacidad de aprendizaje al uso de algoritmos siendo el de Levenberg-Marquardt el de mayor uso por haber demostrado ser el mayor para el desarrollo de esta tecnología. Por otro lado, para el entrenamiento de la ANN se usan datos de los procesos de

voladura ya que presentan características variadas al haberse recopilado en diferentes unidades mineras con diferentes composiciones o tipos de yacimiento (Mendoza, 2021).

Teniendo en cuenta a Sánchez (2020), menciona que los parámetros pueden ser controlables e incontrolables y los mismos son usados como los parámetros de ingreso o predictores para generar el entrenamiento, validación y prueba de la ANN, aun así, solo un porcentaje de los datos se usan en cada uno de estos procesos, situación que permite desarrollar un modelo altamente eficiente en la predicción del índice de fragmentación mismo que se puede añadir gracias al análisis del error cuadrático medio y el coeficiente de correlación  $R^2$ . Por lo que, la investigación busca elaborar un planteamiento de los lineamientos para desarrollar una ANN haciendo uso del lenguaje de programación en el programa de cómputo Matlab R2017b, detallando la secuencia que debe seguir el proceso de forma que este pueda ser probado y usado como entrenamiento de la ANN.

Según Carrión (2020) se tiene como base teórica a la Red Neuronal Artificial, que es también conocida como un proceso de normalización para tener una mejor distribución y así poder entrenar de manera más óptima, también denominado como método de inteligencia artificial el cual es estructurado mediante una computarización. Por otro lado (Aguilar, 2019), señala que la predicción es denominada como un proceso por el cual se emplean comandos, datos, análisis y así poder analizar las diversas variables que permiten inferir lo que sucederá en el futuro, para poder planificar y obtener decisiones con gran cantidad de información. Finalmente, se tiene, que la fragmentación es el procedimiento en el cual el macizo rocoso se encuentra en forma sólida y este es fragmentado en diversos tamaños, mediante una detonación en el proceso de perforación y voladura (Aguilar, 2019).

La presente tesis de investigación presenta los siguientes antecedentes:

Sin embargo Sazid et.al (2021), mencionan que a través de las pruebas de las redes neuronales se obtiene que hasta el 30% de la energía de la explosión se utiliza en la destrucción del macizo rocoso y alrededor del 70% se pierde como calor, causando una propagación directa (tres capas) para 9 entradas, 13 neuronas ocultas y 1 salida (flyrock). Los resultados muestran que la formación de rocas volantes se reduce de 165 m. a 25 m., la red neuronal se puede utilizar eficazmente como una herramienta inteligente para la predicción. Por otro lado, (Moomivand et.al 2022) señalan que el tamaño de los fragmentos de roca volados afecta en gran medida los costos de minería y la eficiencia de producción, el diámetro máximo del orificio ( $\Phi_h$ ) representa los parámetros máximos, como la distancia (S), la carga (B), la dirección (St), la longitud de la carga (Le), la altura del banco (K) y segmentos más grandes usando el GEP, se utilizan parámetros del modelo para predecir  $X_{20}$ ,  $X_{50}$  y  $X_{80}$ . Sólo el 30% de la energía de la explosión se utiliza para aplastar las rocas.

De manera parecida lo indica, Huamani (2020) en su estudio utilizaron redes neuronales artificiales para desarrollar un modelo computacional que mejore las operaciones mediante la optimización de voladura se observaron 47 explosiones, se obtuvo parámetros relacionados con la voladura, como altura del banco de trabajo (h), distancia (S), carga (B), varilla (T), peso del explosivo (Kg), densidad del explosivo (Dex), mineral. densidad (GU) y factor de polvo (PF), se consideró un análisis de fragmentos  $P_{80}$ ,  $P_{50}$  y  $P_{20}$  y se diseñó una arquitectura 8-13-3 utilizando 13 neuronas en la capa oculta con valores RMSE óptimos de 0,009557 y  $R^2$  de 0,87. En el mismo contexto de (Xie, 2021) combinaron varias técnicas de redes neuronales artificiales, para utilizar modelos de predicción computacional de software para optimizar los parámetros de voladura. El 80% de los datos recopilados se utilizó para

el desarrollo y el 20% para pruebas del modelo. También existe un sistema Split-Desktop para analizar la cantidad de fragmentación de roca provocada por las voladuras.

Según Taiwo (2023), menciona que el modelado de redes neuronales artificiales (ANN) utilizan datos de una pequeña cantera de dolomita, los resultados demuestran un coeficiente de polvo superior a  $0,7 - 0,8 \text{ kg/m}^3$  de homogeneidad y para el factor de polvo de  $0,7 \text{ kg/m}^3$  (de 1,6 a 1,7) tiene el índice de homogeneidad más alto, el modelo ANN propuesto funcionó bien en términos de precisión de predicción determinada por cinco niveles de error, con un coeficiente de correlación ( $R^2$ ) de 0,997. Tal como (Linares, 2019) menciona que la predicción de fragmentación durante la voladura desarrollado en base al modelo KUZ-RAM y tecnología de redes neuronales artificiales (ANN) predicción de fragmentación ( $X_{50}$ ) es confirmar que es posible un análisis inferencial con un 95% de probabilidad y que los datos pueden considerarse adecuados, la aproximación más cercana a la verdadera fragmentación  $X_{50}$  se logra con el modelo KUZ-RAM, ya que tiene un factor de escala lineal ( $R^2=0,0065$ ).

En el estudio de Contreras (2020), se desarrolló un modelo de pronóstico multivariado para empresas mineras, está tratando de desarrollar un modelo que pueda predecir el comportamiento no lineal de la potencia se obtiene utilizando como variables de respuesta variables mineralógicas, variables del operador y potencia del molino. Para ello, (Carranza, 2022) propone utilizar modelos de redes neuronales y modelos de bosques aleatorios y compararlos con otros modelos. El resultado es que el error del modelo de bosque aleatorio es del 0,76%, mientras que el error de la red neuronal es del 1,40%. Estos errores son mucho más pequeños que el error del 3,04% (clásico) del modelo. Finalmente se concluyó que el nuevo modelo de aprendizaje automático prediga y adapte los datos mejor que los modelos clásicos. En el estudio de (López, 2019), señala que para obtener el modelo

esperado de la distribución de fragmentos de producto explosivo  $X_{50}$  y  $X_{80}$ , usan ecuaciones que describen la distribución del tamaño de las partículas proporcionado por el software utilizando el método de análisis estadístico, se obtuvo un intervalo de confianza aceptable del 95%.

Según el estudio de Mendoza (2021) menciona que el sistema predictivo para la fragmentación de roca está basado en aplicar tecnología durante la voladura de roca, emplea con siete variables como parámetros para predecir una explosión ( $D$ ,  $S/B$ ,  $H/B$ ,  $T/B$ ,  $Pf$ ,  $E$ ,  $X_B$ ,  $X_{50}$ ). Como factor de potencia se considera al explosivo. Obteniendo como resultado que el factor de potencia está relacionado con el peso (kg) del explosivo utilizado con el volumen de roca detonante ( $m^3$ ). En la investigación de (Orellana et al., 2019), realizó la implementación de la importancia de utilizar modelos revolucionarios como las redes neuronales artificiales (RNA), para así optimizar la minería proporcionando los mejores fragmentos para el proceso de minería, se reduce el tiempo de molienda y se aumenta la productividad. Los resultados muestran que el modelo ANN logró un ajuste lineal de aproximadamente el 99,03%, mientras que otros modelos, como MVR, lograron un ajuste lineal del 65%, mientras que el modelo KUZ-RAM fue del 0,65%.

En el estudio de Huanca (2018), se enfoca en resolver el problema de la voladura y trituración insuficientes del mineral y mejorar la capacidad de procesamiento de la trituradora primaria, se llevaron a cabo estudios relevantes y se concluyó que el uso del modelo matemático de predicción de voladuras de Kuz-Ram puede reducir el rendimiento de la voladura secundaria e interrupción, la utilización en tierra se redujo del 20% a menos del 5% y la capacidad del concentrador aumentó de 720 TMS por día a 850 TMS por día. Por otro lado, (Flores, 2019) explica en su estudio, que utilizó el software Wipfrag para medir los fragmentos que se desarrollan a través de las voladuras, logrando reconocer que

durante el proyecto de exploración produjeron menos desechos que cualquier proyecto anterior, midiendo 6,02 pulgadas, lo que indica la eficiencia superior de la mina.

En base a lo antes mencionado la pregunta de investigación que se plantea es: ¿Cómo desarrollar una red neuronal artificial para la predicción del índice de fragmentación ( $X_{50}$ ) en las operaciones de voladura en minería superficial 2024?

Planteando como objetivo general de la tesis: Desarrollar una Red Neuronal Artificial (ANN) para predecir el Índice de Fragmentación Medio ( $X_{50}$ ) en las operaciones de voladura en minería superficial 2024, haciendo uso de del programa computacional Matlab R2017b. Apoyándose de los siguientes objetivos específicos: a) Determinar los datos que se usaran como predictores en las operaciones de voladura en minería superficial 2024. b) Determinar los predictores que tienen mayor correlación con el resultado esperado usando la estadística descriptiva de la Red Neuronal Artificial (ANN) haciendo uso del programa computacional Minitab19. c) Analizar las gráficas resultantes para determinar el nivel de predicción del Índice de Fragmentación Medio ( $X_{50}$ ) y describir los principales retos del entrenamiento de la Red Neuronal Artificial en las operaciones de voladura en minería superficial 2024.

La presente investigación tiene como hipótesis general que, a través del desarrollo de la ANN usando el programa de cómputo Matlab R2017b, se obtendrá una correlación directa entre los predictores y el Índice de Fragmentación Medio ( $X_{50}$ ) de forma que se obtenga resultados óptimos para el desarrollo de las operaciones de voladura en minería superficial 2024. Mediante esta investigación se pretende demostrar que el nivel de predicción de la ANN, es cercano al Índice de Fragmentación Medio Real.

Hipótesis Nula: Al menos uno de los 7 predictores no influye en la predicción del Índice de Fragmentación ( $X_{50}$ ).

Hipótesis alternativa: Al menos uno de los 7 predictores influye en la predicción del Índice de Fragmentación ( $X_{50}$ ).

El presente estudio emplea como justificación teórica, aplicando los conocimientos de software de cómputo Matlab R2017b y la estadística descriptiva usando el programa de cómputo Minitab 19 para correlacionar la variable independiente con la dependiente. En tanto para la justificación práctica emplea el uso del control predictivo de fragmentación en los procesos de voladura, permitirá optimizar las operaciones mineras y por lo cual se reducirán los costos.

## CAPÍTULO II: METODOLOGÍA

La presente investigación, es de tipo aplicada, ya que se propone una solución mediante la cual se busca obtener mejorar el estado actual de la fragmentación por voladura a una situación mejor. El enfoque de la investigación es mixto ya que se analizará datos no numéricos y numéricos que permitan plantear los lineamientos y analizar los retos para la aplicación de una Red Neuronal Artificial en operaciones mineras superficiales 2024; específicamente en el proceso de voladura. Presenta un alcance explicativo en el cual se tiene como propósito establecer una identificación clara de los hechos y las implicancias que se presentan en el estudio de investigación los retos que conlleva implementar inteligencia artificial en las operaciones mineras y que permita la toma de decisiones en base al análisis de datos y creación de un nuevo conocimiento e información a través de la generación de modelos predictivos. La investigación no experimental podría definirse aquella que se realiza sin manipulación intencional de las variables. La investigación presenta un diseño no experimental ya que en ella no se modificará la variable dependiente (Índice de Fragmentación Medio  $X_{50}$ ) de estudio, se trata de una investigación donde no se varía de forma deliberada las variables, solo se observa fenómenos tal como sucede desde su contexto natural y después poder analizarlos, con corte longitudinal ya que se tomarán datos de acuerdo a los avances y diferentes periodos de tiempo de la implementación de Red Neuronal Artificial (Sampieri et al, 2014).

La investigación tiene como población a Todas las operaciones de voladura en minería superficial.

La investigación plantea como muestra a 90 operaciones de voladura en minería superficial.

## **Variable Independiente**

Redes neuronales artificiales.

## **Variable Dependiente**

Índice de Fragmentación Medio ( $X_{50}$ )

Las técnicas a utilizar son: la observación directa y el análisis documental. Con la observación directa se recoge datos del  $X_{50}$  (Índice de Fragmentación Medio) obtenidas en las pilas del material volado, en las fichas de observación. El análisis documental se utilizó para obtener información de los modelos computacionales como también de las herramientas estadísticas y el procedimiento para utilizar el Matlab y Minitab; así mismo esta técnica se utilizó para la búsqueda de antecedentes y marco teórico referido a la investigación.

El instrumento a utilizar es el siguiente:

Instrumento 1: Ficha de Datos usados como predictores en la (ANN) para las operaciones de voladura (Ver Anexo 1).

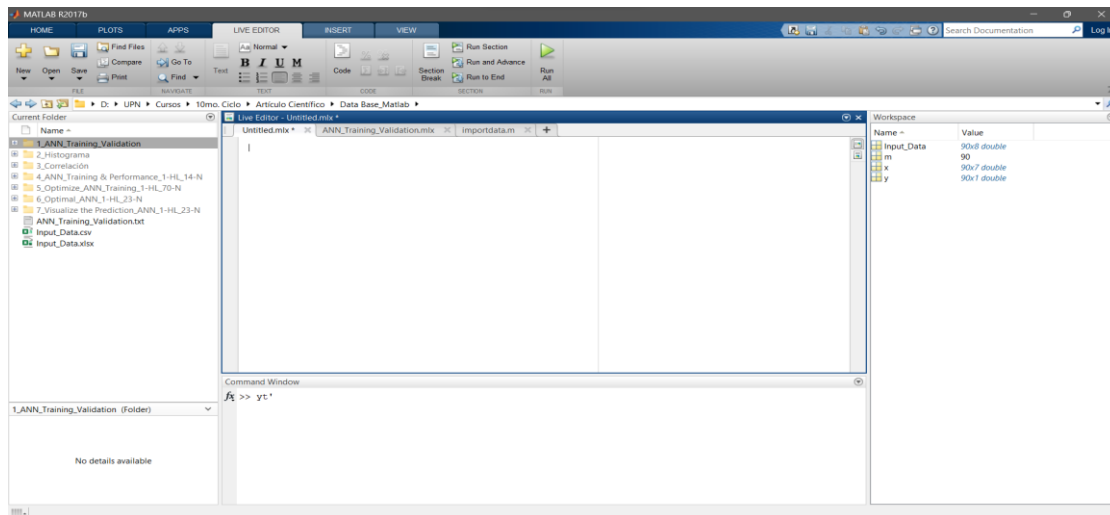
Dentro de los Materiales se tiene:

- Laptop Lenovo RYZEN 7
- Software Matlab R2017b
- Software Minitab 19
- Software Excel
- Hojas Bond A4
- Fotocopias
- Lapiceros

A continuación, tenemos el procedimiento y análisis de datos, se inicia principalmente realizando un entrenamiento y rendimiento que desarrolla la Red Neuronal Artificial (ANN), en la cual es importante familiarizarse con el interfaz de Matlab R2017b para poder entender el funcionamiento del programa en cuanto a la programación de la Red Neuronal Artificial desde su arquitectura hasta su entrenamiento, validación y prueba.

## Figura 1

*Interfaz de Matlab R2017b para el Desarrollo de la Red Neuronal Artificial (ANN)*



En esta sección, es importante trabajar con la pestaña Live Editor, misma que nos permitirá ingresar textos y códigos para entender el desarrollo de la ANN.

El primer paso para lograr un entrenamiento de excelencia de la ANN es importar la data de los parámetros controlables e incontrolables, así como el Índice de Fragmentación Media Real ( $X_{50Real}$ ) obtenida en estudios previos y que fueron recopilados por (Hudaverdi et al. 2010), en 90 procesos de voladura analizados en 9 operaciones mineras en el mundo especialmente en Europa.

Los datos fueron procesados en forma de matrices y el comando para lograr la importación de la data es “Input Data”. En este punto, lo importante es determinar los datos que se usarán en la capa de entrada conocidos como “predictores” (datos de “x”) y los datos que se esperan como predicción (datos de “y”) los cuales se muestran en la capa de salida. Para este caso, las matrices serán de 90 x 7 y 90 x 1 respectivamente y la longitud (m) de 90 datos. El Código de Programación usado en esta sección es el siguiente:

## Figura 2

*Código de ingreso de datos a Matlab R2017b*

```
Input_Data=importdata('Input_Data.csv');  
x=Input_Data(:,1:7);  
y=Input_Data(:,8);  
m=length(y);
```

En este punto es importante tener digitalizada la data en una hoja Excel, misma que será guardada como archivo con extensión “csv” para poder usarla en Matlab R2017b.

Importada la data, como segundo paso debemos visualizar la distribución de los datos de entrada o predictores para analizar la eficiente de esta distribución y de ser necesario, desarrollar un proceso de normalización. Esta visualización se hace con histogramas de frecuencia.

Los datos usados como predictores son los siguientes: S/B, H/B, B/D, T/B, Pf, XB, E mismos que se desarrollan en la Tabla 1.

**Tabla 1**

*Código denominación de predictores*

Denominación	Predictor
S/B	Spacing to Burden (Espaciamiento de Carga)
H/B	Bench Height to drilled burden (Altura del banco a perforar para cargar)
B/D	Burden to hole diameter (Diámetro del taladro de carga)
T/B	Stemming to burden (Taco de la carga)
Pf	Power factor (Factor de Poder)
XB	Mean block size (Tamaño principal del bloque)
E	Elastic modulus (módulo de elasticidad)

El código de programación usado para la visualización de los gráficos de histogramas de distribución de los predictores se muestra en la Figura 3.


**Figura 3**


*Código de programación para la visualización de los histogramas distribución de predictores*

```
histogram(x(:,7),10);
```

**Figura 4**

*Histogramas de distribución de los datos usados como predictores para el entrenamiento de la ANN*





Visualizados y analizados los histogramas de distribución de los predictores, se concluye que ninguno tiene una distribución normalizada, siendo el histograma de predictor Mean Block Size (tamaño principal del bloque) el de mejor distribución. Por tanto, un tercer paso del entrenamiento de la ANN es la normalización de los datos entre 0 y 1, esto con la finalidad de asegurarnos de no usar los “ceros” en el entrenamiento y tener una mejor distribución de los datos de los predictores.

Para lograrlo, es necesario usar una fórmula matemática para los datos de salida agregando el 1 en una ecuación logarítmica y transformar las matrices originales “x” y “y” en “x2” y “y2”. El código de programación y las gráficas de histograma de los datos normalizados resultantes se muestran a continuación.

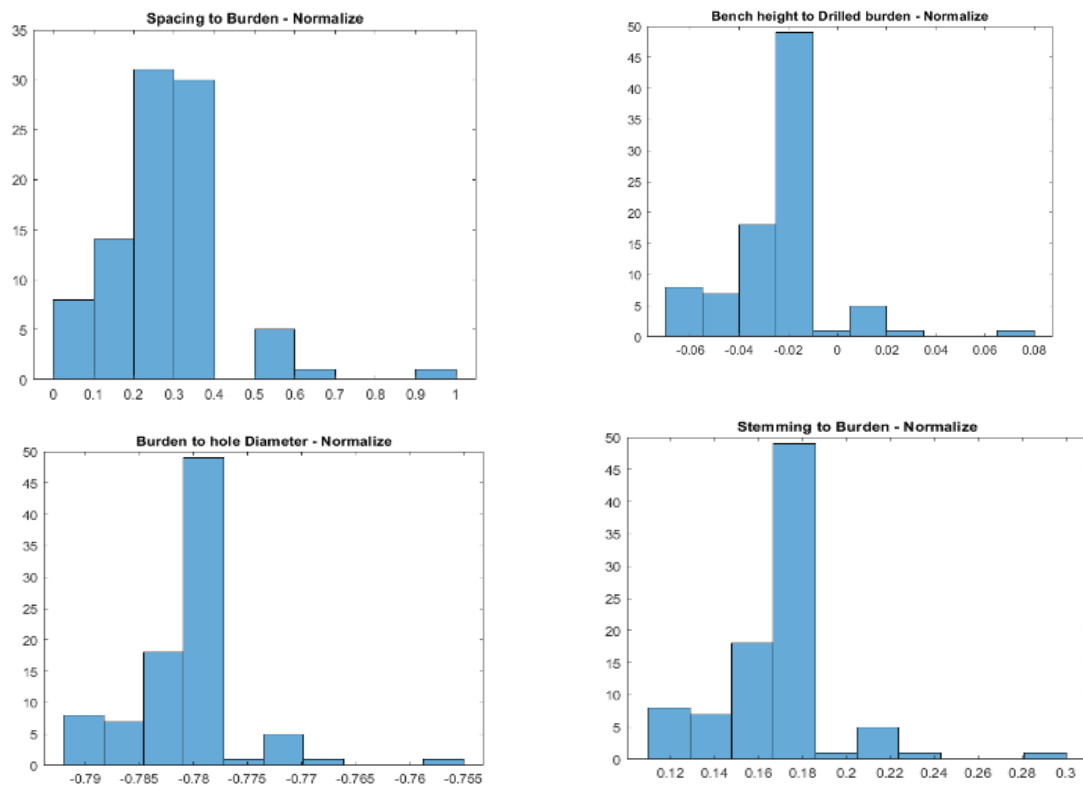
**Figura 5**

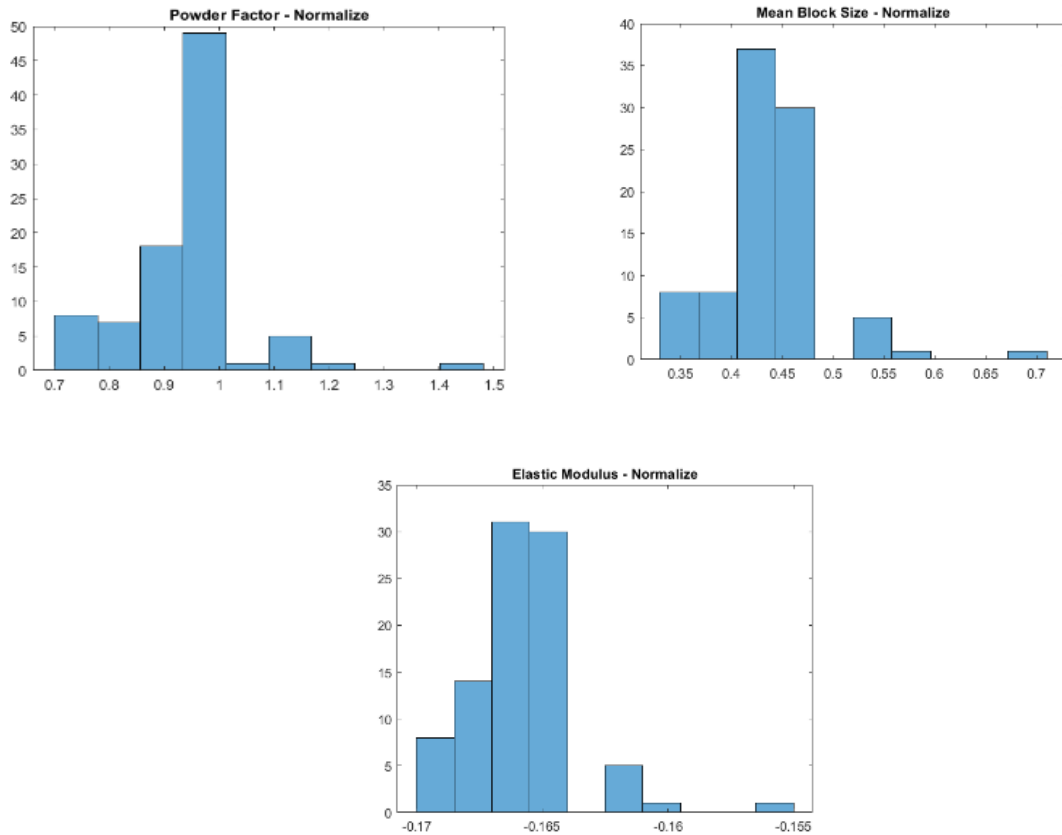
*Código de programación para la normalización de los datos de los predictores y la generación de los nuevos Histogramas de Frecuencia de los datos normalizados*

```
y2=log(1+y);
for i=1:7
    x2(:,i)=(x(:,i)-min(x(:,i)))/(max(x(:,i))-min(x(:,i)));
end
histogram(x2(:,1),10);
```

**Figura 6**

*Histogramas de distribución de los datos normalizados*





Nótese que ahora todos los datos están normalizados en valores entre el 0 y 1 y que las distribuciones son mucho más eficientes.

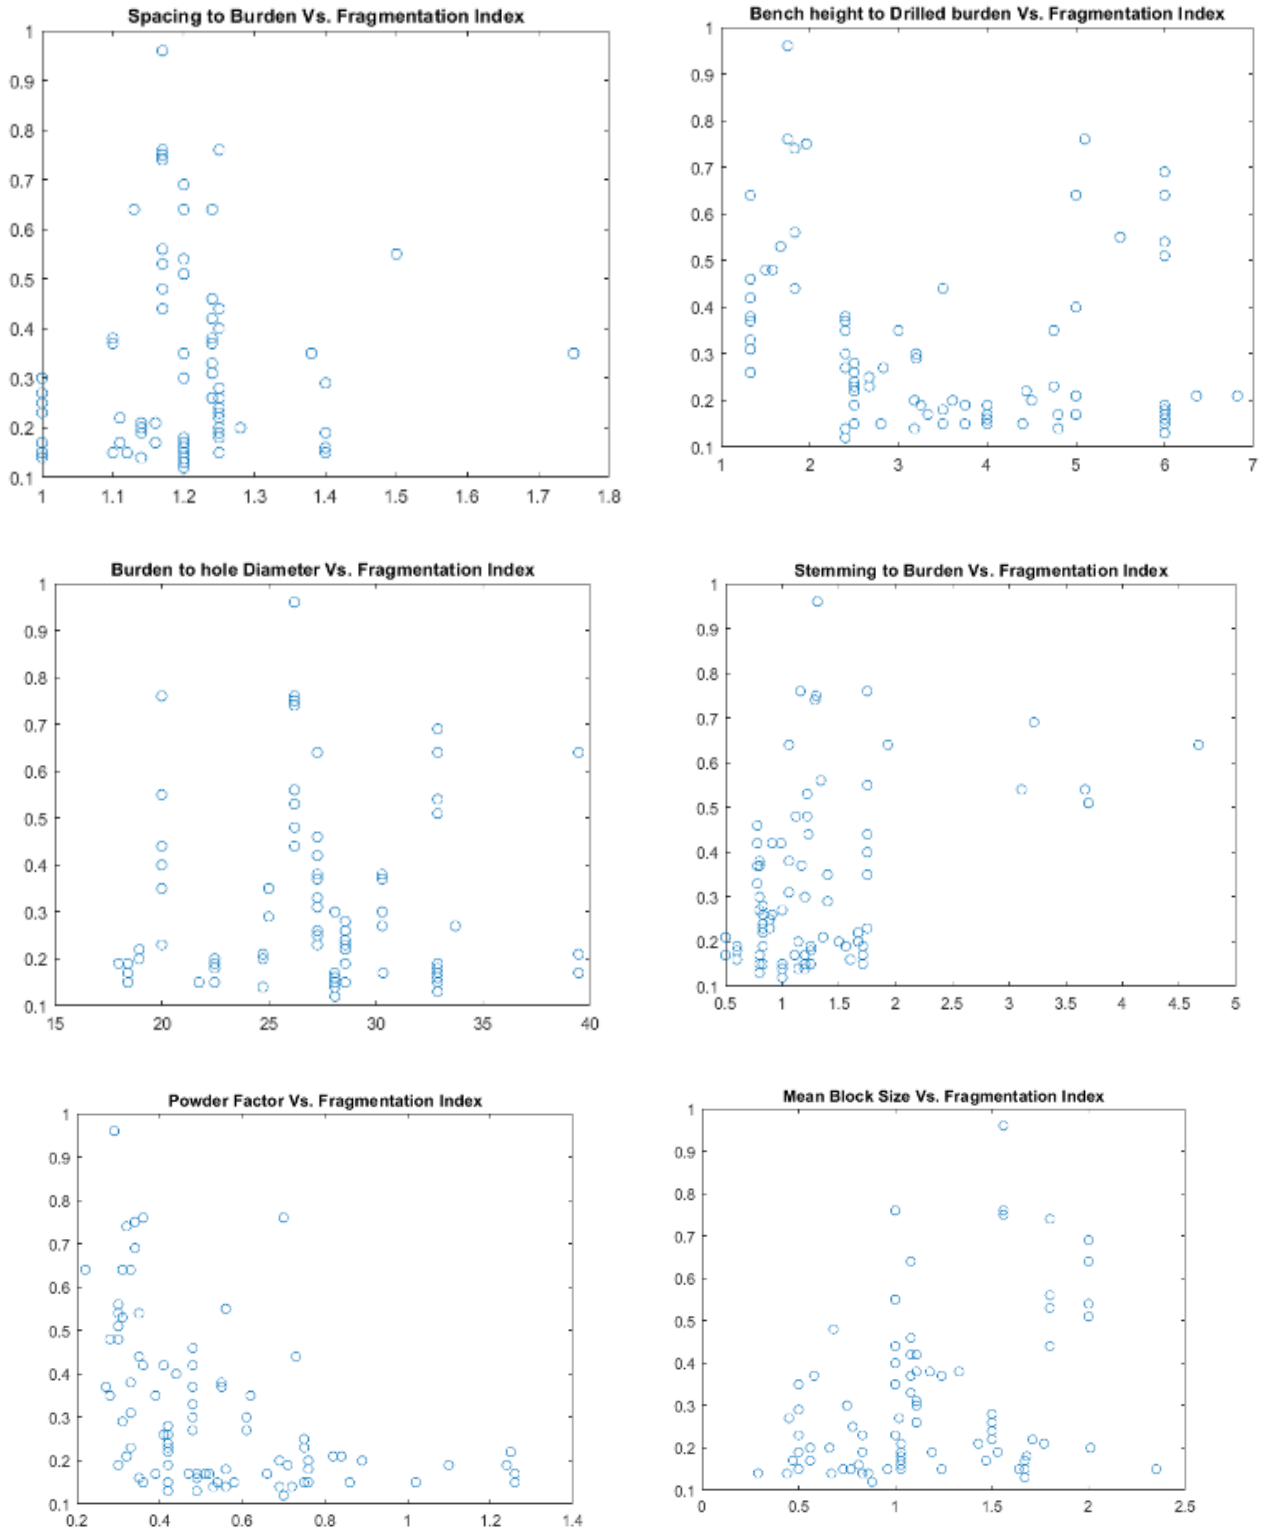
### Figura 7

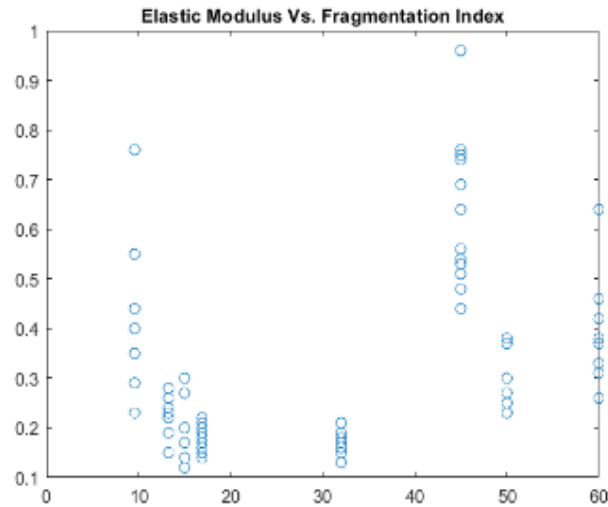
*Código de programación para determinar la correlación entre los predictores y el resultado esperado ( $X_{50Real}$ )*

```
plot(x(:,7),y,'o')
```

**Figura 8**

*Gráficas de correlación entre los predictores y el resultado esperado ( $X_{50}Real$ )*





Analizadas las gráficas, concluimos que ninguna de ellas forma una línea de tendencia que permita concluir que existe una correlación directa entre los datos usados como predictores y el dato esperado ( $X_{50Real}$ ), por lo que se debe trabajar con los datos normalizados (matrices normalizadas “x2” y “y2”) y esperar una mejor dispersión alineada a la tendencia de predicción. El código de programación usado, así como las gráficas de correlación de los datos predictores normalizados se muestran en las Figuras 9 y 10.

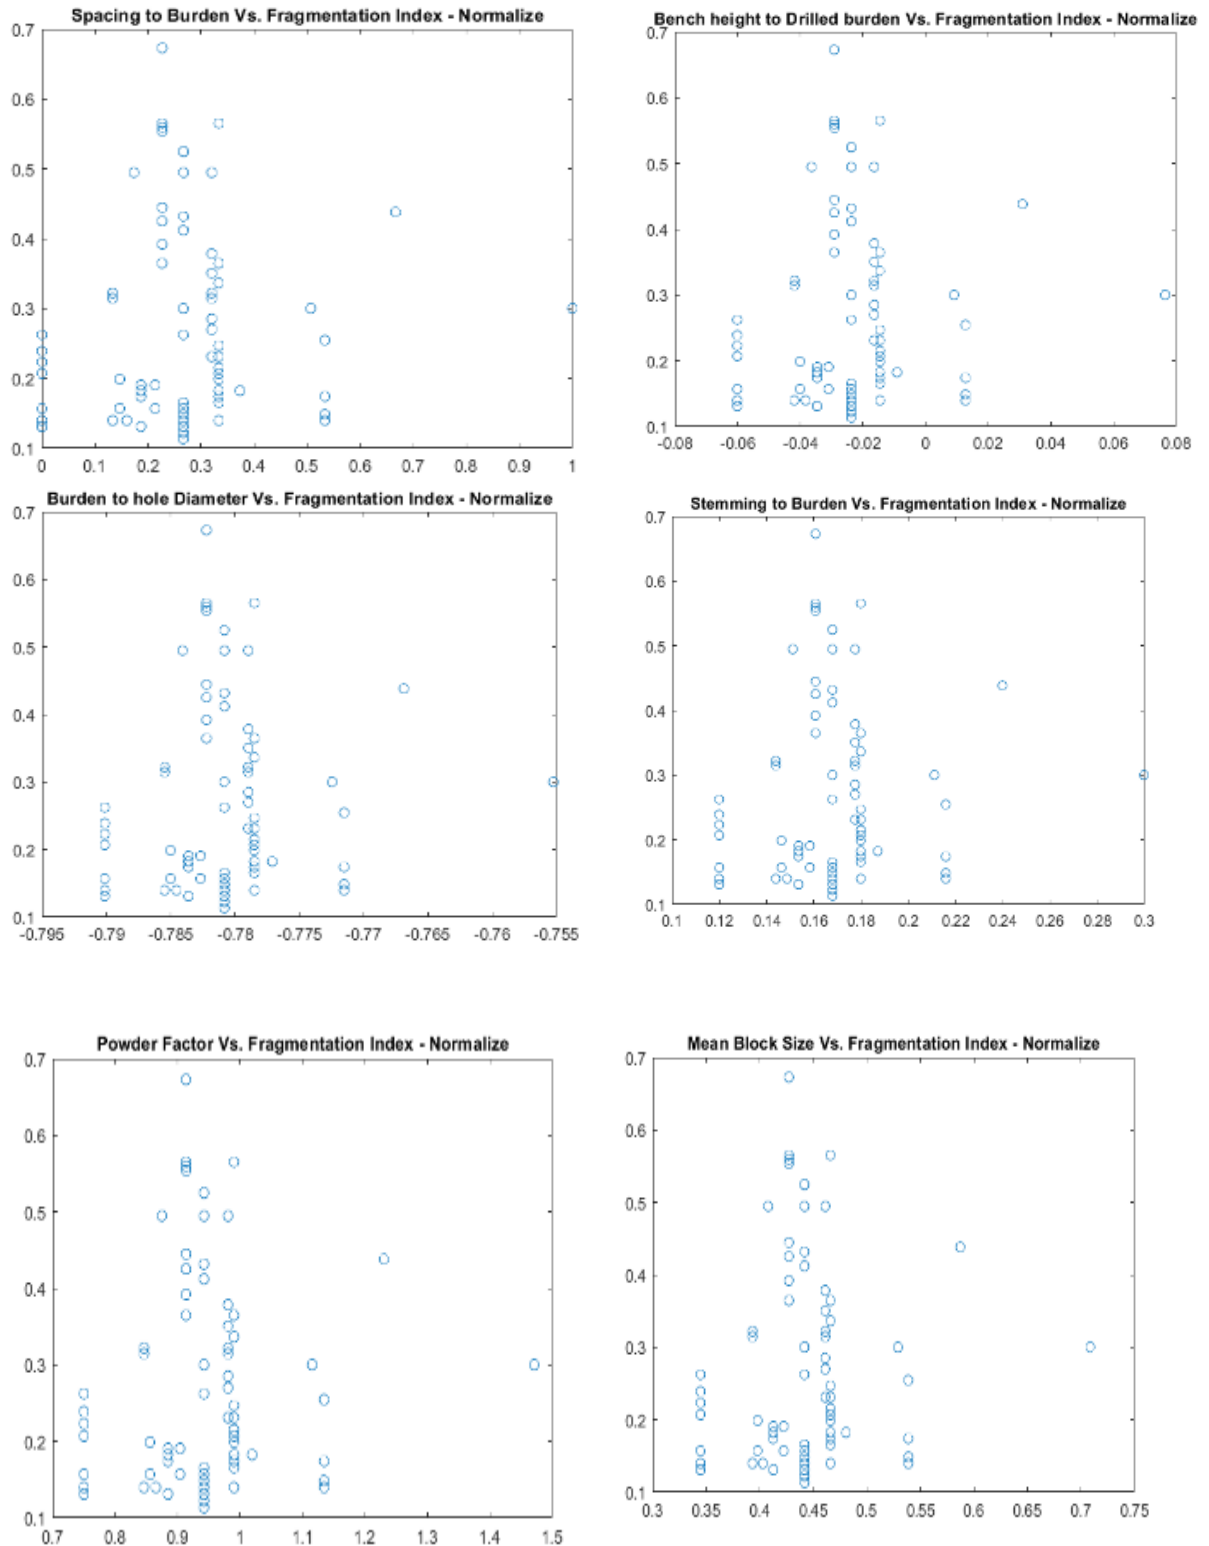
### Figura 9


*Código de programación para determinar la correlación entre los predictores normalizados y el resultado esperado ( $X_{50Real}$ )*

```
plot(x2(:,7),y2,'o');
```

**Figura 10**

*Gráficas de correlación entre los predictores normalizados y el resultado esperado ( $X_{50Real}$ )*





En las gráficas se observa una mejor correlación de los predictores normalizados con el  $X_{50Real}$ , todos con una tendencia hacia sus valores inferiores, lo que indica que cada uno de ellos tienen una gran correlación con el resultado final de predicción del  $X_{50Teórico}$ .

Culminados estos 4 pasos o procedimientos previos, se puede ya dar inicio al proceso de propio de entrenamiento de la ANN. Por tanto, el quinto paso es diseñar la arquitectura de la ANN, misma que tendrá una capa de ingreso, una capa oculta y una capa de salida. En este paso, se puede escoger un número aleatorio de neuronas, para nuestro caso será de 14 el algoritmo usado para el entrenamiento de la ANN será el de Levenberg-Manquardt.

Un dato importante en este paso es determinar el porcentaje de datos normalizados que se usarán para el entrenamiento, la validación y la prueba de la ANN, para el caso, estos valores serán de 80% (entrenamiento), 10% (validación) y 10% (prueba), lo que significa que, de los 90 conjuntos de datos, se usará solo un porcentaje de ellos para cada procedimiento de entrenamiento de la ANN. Finalmente, un requerimiento adicional en este paso es generar las transpuestas de las matrices “x2” y “y2” denominando a estas nuevas matrices como “xt” y “yt”. El código de programación utilizado, el reporte y las gráficas del entrenamiento se muestran en las Figuras 11, 12 y 13 respectivamente.

**Figura 11**

Código de programación para diseñar la arquitectura de la ANN, seleccionar el número de capas ocultas y determinar los porcentajes de datos a usar para su entrenamiento, validación y prueba

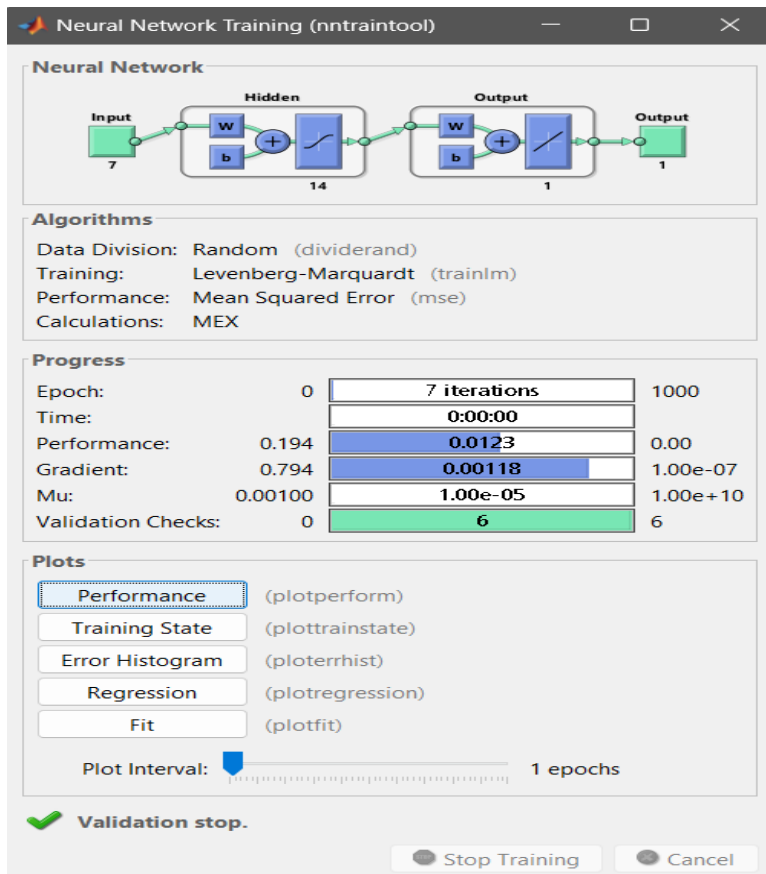
```

xt=x2';
yt=y2';
hiddenLayerSize=(14);
net=fitnet(hiddenLayerSize);
net.divideParam.trainRatio=80/100;
net.divideParam.valRatio=10/100;
net.divideParam.testRatio=10/100;
[net,tr]=train(net,xt,yt);

```

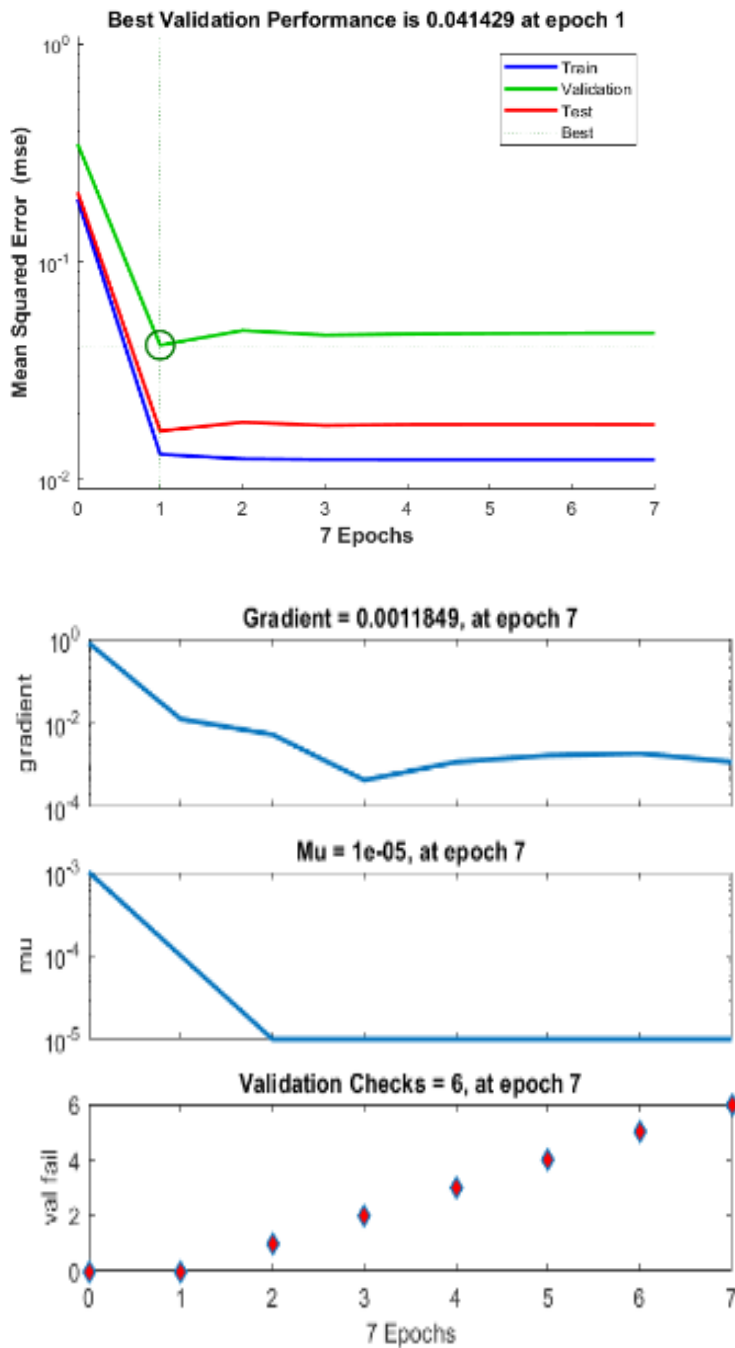
**Figura 12**




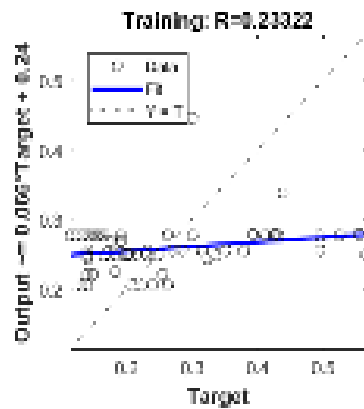

Reporte del entrenamiento de la ANN con 14 neuronas en la capa oculta escogidas de forma aleatoria



**Figura 13**

*Graficas Generadas en el entrenamiento de la ANN con 14 neuronas en la capa oculta*





Se puede observar, en este primer entrenamiento con 14 neuronas en la capa oculta que la curva de validación llega al punto más bajo de Error Cuadrático Medio (MSE), parámetro usado para evaluar performance o rendimiento de la ANN, cuyo valor oscila entre  $10^{-1}$  y  $10^{-2}$  lo que sugiere un gran nivel de predicción y correlación con los datos medidos en campo. Por otro lado, los datos están alrededor de la línea de ajuste, pero esta se encuentra desplazada en relación a la línea de tendencia, aun así, se corrobora una gran correlación entre los datos predichos y los datos medidos.

Entrenada la red, es necesario evaluar su rendimiento, para lo cual se calculará la Raíz del Error Cuadrático Medio (RMSE) de los siete predictores, pero, por separado, primero con el 80% de los datos usados para el entrenamiento, luego con el 10% de los datos usados para la validación y finalmente con el 10% de los datos usados para la prueba de la ANN, en números significa que se usarán 72 datos en el caso del entrenamiento, 9 datos en el caso de la validación y 9 datos en el caso de la prueba del modelo de predicción, siendo este el sexto paso del entrenamiento de una ANN.

El cálculo de esta Raíz del Error Cuadrático Medio se calcula restando los datos predichos menos los datos reales de acuerdo a los siguientes códigos de programación mostrados en la Figura 14.

## Figura 14

*Códigos de programación para determinar el RMSE y evaluar el rendimiento del entrenamiento de la ANN*

```
yTrain=exp(net(xt(:,tr.trainInd)))-1;  
yTrainTrue=exp(yt(tr.trainInd))-1;  
sqrt(mean((yTrain-yTrainTrue).^2))  
yVal=exp(net(xt(:,tr.valInd)))-1;  
yValTrue=exp(yt(tr.valInd))-1;  
sqrt(mean((yVal-yValTrue).^2))  
yTest=exp(net(xt(:,tr.testInd)))-1;  
yTestTrue=exp(yt(tr.testInd))-1;  
sqrt(mean((yTest-yTestTrue).^2))
```

Los resultados de la RMSE de los procesos de entrenamiento, validación y prueba de la ANN se muestran en la Figura 15 respectivamente.

## Figura 15

*RMSE del entrenamiento, validación y prueba de la ANN respectivamente*

```
ans = 0.1678
```

```
ans = 0.2535
```

```
ans = 0.1997
```

Mediante los resultados obtenidos en el entrenamiento de la ANN se determina que el porcentaje de error del conjunto de datos predichos es menor a 0.5%, lo que significa que el nivel de predicción es muy alto, pero, además, al no tener una gran diferencia entre los resultados del conjunto de datos usados para el entrenamientos, validación y prueba significa que la red no está AJUSTADA, por lo que su aplicación ha sido la adecuada, siendo estos resultados exitosos como entrenamiento de la ANN.

Comprobado el rendimiento de la ANN en la predicción del  $X_{50\text{Teórico}}$ , podemos optimizar su número de neuronas en la capa oculta como sétimo paso. Para esto, se entrena la ANN con diferentes números de neuronas, desde 1 neurona hasta 70 neuronas en su capa oculta con la finalidad de analizar su RMSE del conjunto de datos usados para la validación. Este análisis del RMSE de los datos usados para la validación de la ANN, nos permite identificar el valor más bajo, este será el valor que determina cual es el número óptimo de neuronas en la capa oculta (ANN).

Este proceso de optimización consta de 3 sub procesos que se definen como:

- Diseño de la arquitectura de la ANN: Tamaño de la ANN, número de capas ocultas, número de neuronas, cantidad de predictores y respuesta esperada en la capa de salida.
- Entrenamiento de la ANN: Como se ha desarrollado y explicado en el paso 5.
- Determinación del RMSE más bajo del conjunto de datos de validación de la ANN: Este será el dato que responderá a la pregunta de la cantidad óptima de neuronas en la capa oculta para obtener el mejor rendimiento de predicción de la ANN.

Esta serie de entrenamientos nos permitirá no solo seleccionar el número óptimo de neuronas en la capa oculta, sino que evitará que el modelo de predicción sea muy simple o muy complejo, entendiendo que un modelo insuficientemente ajustado (simple), por

ejemplo, con una sola neurona, o muy ajustado, por ejemplo, con 100 neuronas, generarán datos de predicción muy diferentes a los reales o serán imposibles de generalizar respectivamente. Se presenta además el resultado del último entrenamiento con 70 neuronas en la capa oculta para notar la diferencia con el entrenamiento inicial hecho con 14 neuronas, así como los nuevos RMSE generados, en dónde se verifica que ambos entrenamientos, arrojan resultados similares en cuanto a su capacidad de predicción.

### Figura 16

*Códigos de programación para entrenar a la ANN desde 1 hasta 70 neuronas en la capa oculta y determinación del RMSE*

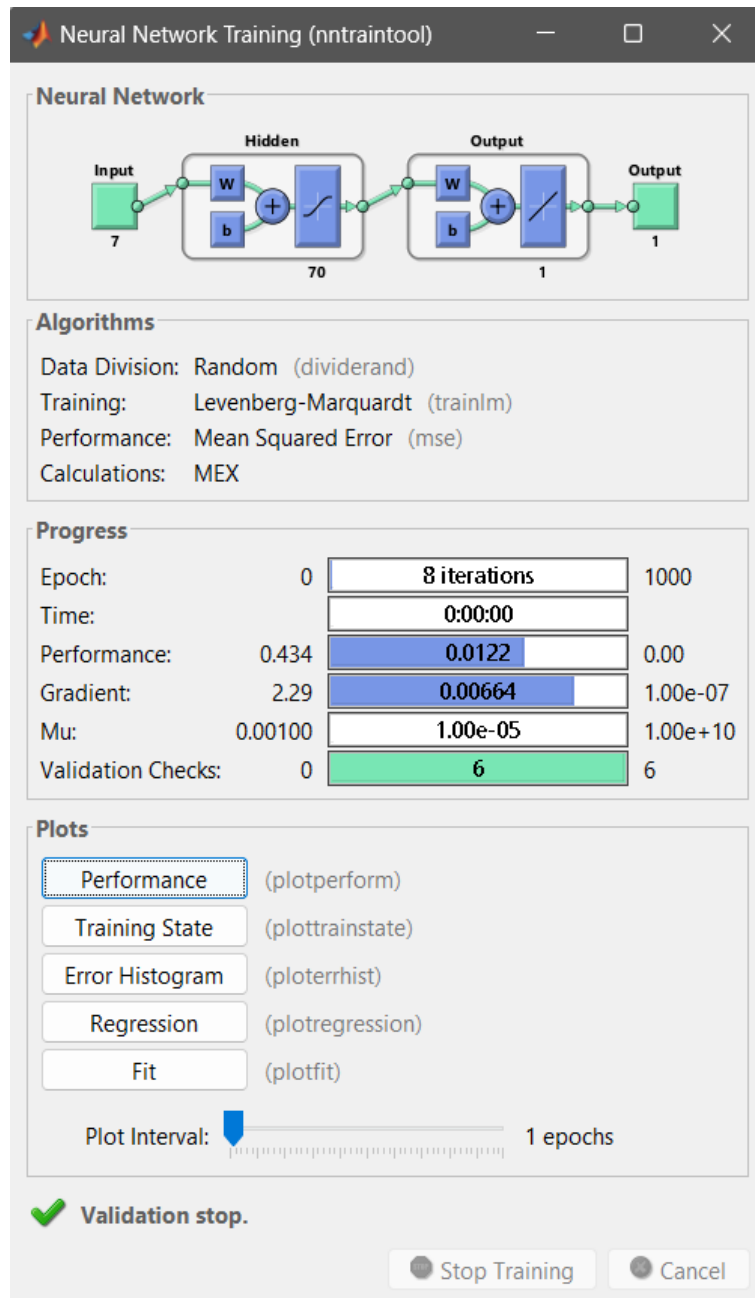
```
for i=1:70
    %defining the architecture of the ANN
    hiddenLayerSize=i;
    net=fitnet(hiddenLayerSize);
    net.divideParam.trainRatio=80/100;
    net.divideParam.valRatio=10/100;
    net.divideParam.testRatio=10/100;

    %training the ANN
    [net,tr]=train(net,xt,yt);

    %determine the error of the ANN
    yTrain=exp(net(xt(:,tr.trainInd)))-1;
    yValTrue=exp(yt(tr.valInd))-1;
    yTestTrue=exp(yt(tr.testInd))-1;
    yTrainTrue=exp(yt(tr.trainInd))-1;
    yVal=exp(net(xt(:,tr.valInd)))-1;
    yTest=exp(net(xt(:,tr.testInd)))-1;
    rmse_train(i)=sqrt(mean((yTrain-yTrainTrue).^2)) %RMSE of training set
    rmse_val(i)=sqrt(mean((yVal-yValTrue).^2)) %RMSE of validation set
    rmse_test(i)=sqrt(mean((yTest-yTestTrue).^2)) %RMSE of testing set
end
```

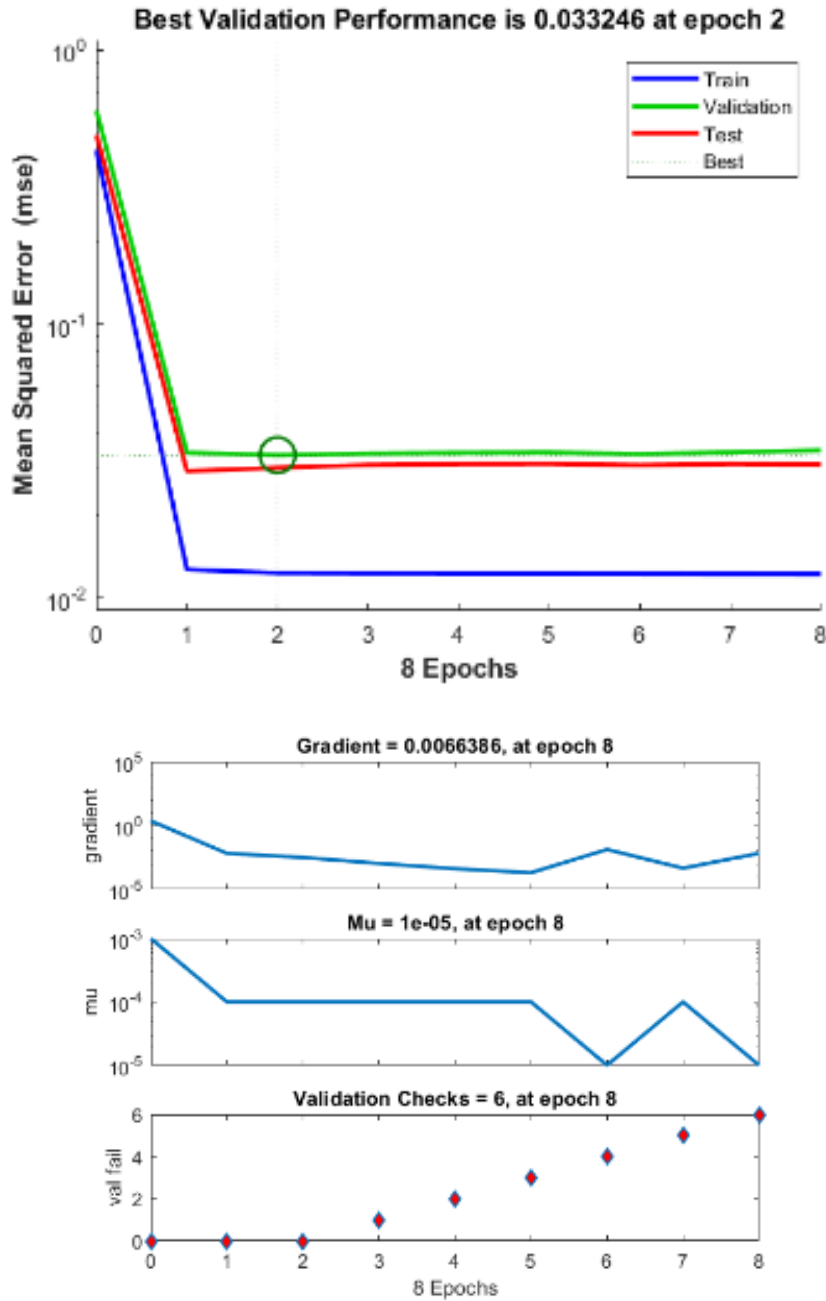
**Figura 17**


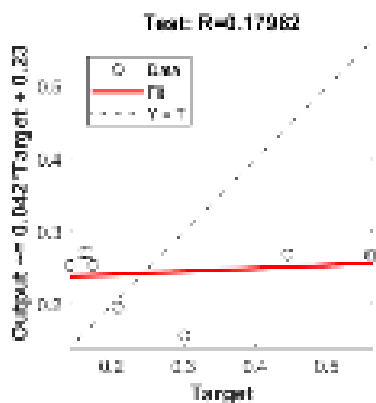
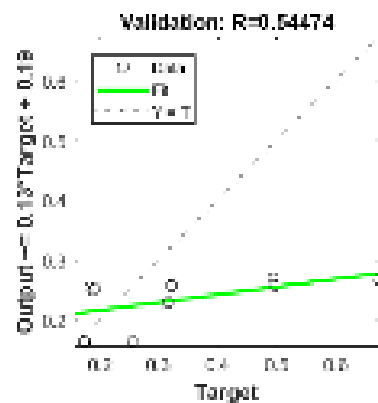
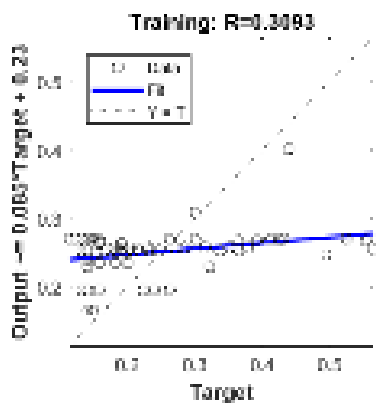

*Reporte del entrenamiento de la ANN con 70 neuronas en la capa oculta como último entrenamiento de la serie de entrenamientos de 1 a 70 neuronas en la capa oculta*



**Figura 18**

*Graficas Generadas en el entrenamiento de la ANN con 70 neuronas en la capa oculta como último entrenamiento de la serie de entrenamientos desde 1 a 70 neuronas*





## Figura 19

*RMSE del entrenamiento, validación y prueba de la ANN con 70 neuronas en la capa oculta en la serie de entrenamientos desde 1 a 70 neuronas*

```
rmse_train = 0.1845  
rmse_val = 0.1740  
rmse_test = 0.1922
```

Se continúa con la selección del número óptimo de neuronas en la capa oculta de la ANN. Para poder visualizar los valores de los RMSE en los 70 entrenamientos con neuronas de la 1 a la 70 en la capa oculta, se deberá generar una gráfica de tendencia que nos permita no solo analizar los resultados del entrenamiento, sino que se podrá identificar, con los datos usados para el entrenamiento, validación y prueba de la ANN, el valor más bajo de RMSE en la curva de validación, este dato, como ya se mencionó, nos dará el número óptimo de neuronas para la ANN.

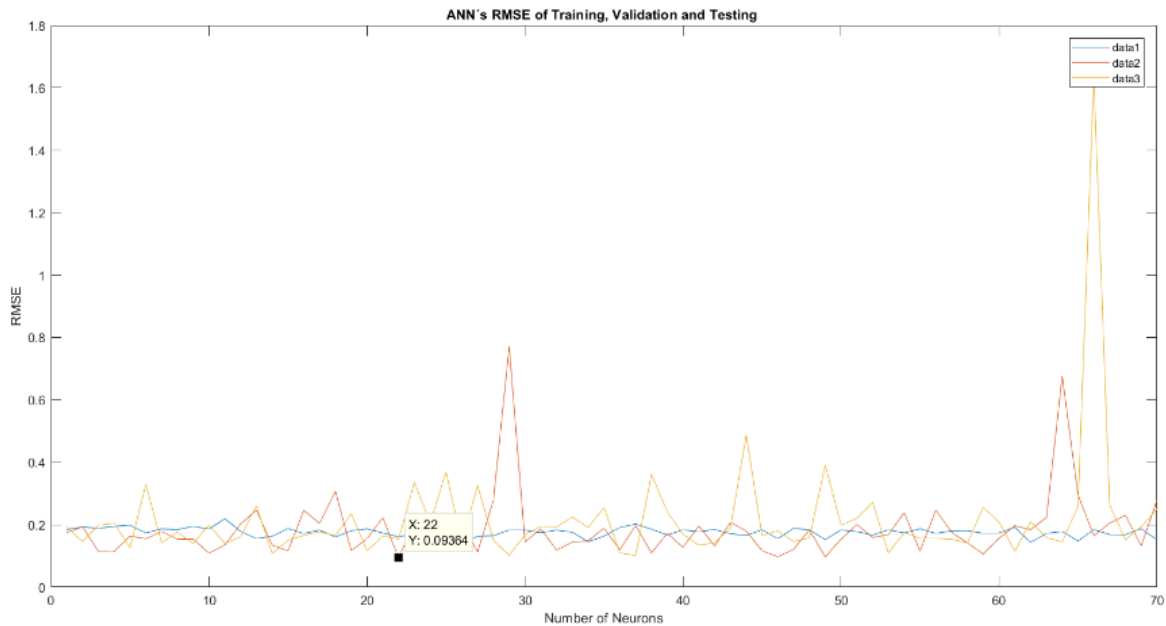
## Figura 20

*Códigos de programación para generar las curvas del RMSE del entrenamiento, validación y prueba de la ANN en la serie de entrenamientos desde 1 a 70 neuronas en la capa oculta*

```
plot(1:70,rmse_train);hold on;  
plot(1:70,rmse_val);  
plot(1:70,rmse_test);hold off;
```

**Figura 21**

Gráfico de los 70 RMSE del entrenamiento (data 1), validación (data 2) y prueba (data 3) para determinar el valor más bajo del RMSE de la curva de validación (x) para determinar el número óptimo de neuronas de la ANN



El gráfico nos determina el número óptimo de neuronas en la capa oculta para entrenar, validar y probar la ANN, mismo que nos muestra que el RMSE de la curva de validación, siendo el valor más bajo de RMSE de esta curva de validación 22, valor que nos determina el número óptimo de neuronas en la capa oculta para lograr los mejores resultados de predicción de la ANN.

Con esta información, volvemos a entrenar la ANN esta vez con el número óptimo de neuronas en la capa oculta de la ANN y volvemos a calcular el RMSE para obtener el verdadero porcentaje de error de predicción de la ANN siendo este el octavo paso del entrenamiento de la ANN.

**Figura 22**

*Códigos de programación para entrenar a la ANN con el número óptimo de neuronas (22) en la capa oculta*

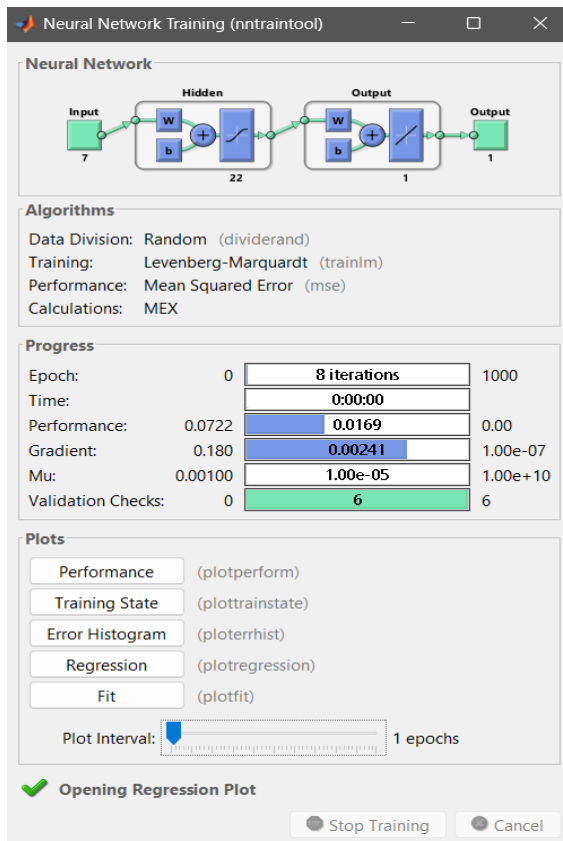
```

xt=x2';
yt=y2';
hiddenLayerSize=(22);
net=fitnet(hiddenLayerSize);
net.divideParam.trainRatio=80/100;
net.divideParam.valRatio=10/100;
net.divideParam.testRatio=10/100;
[net,tr]=train(net,xt,yt);

```

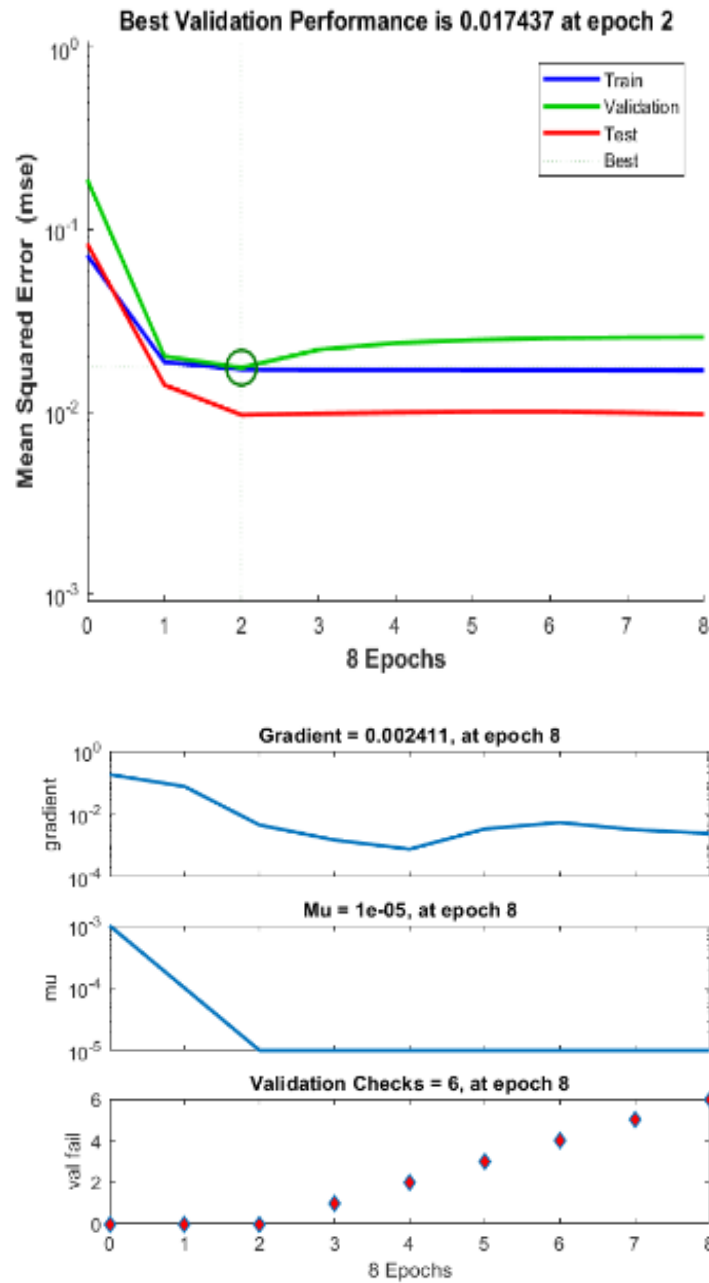
**Figura 23**

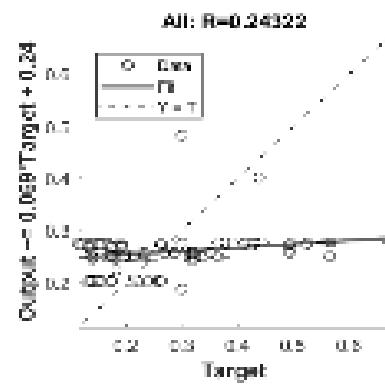
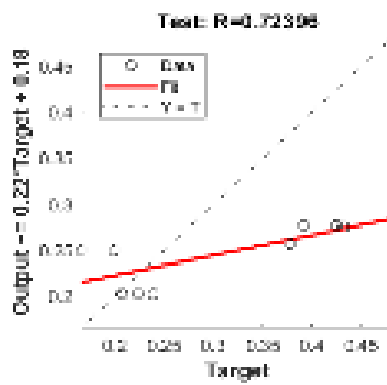

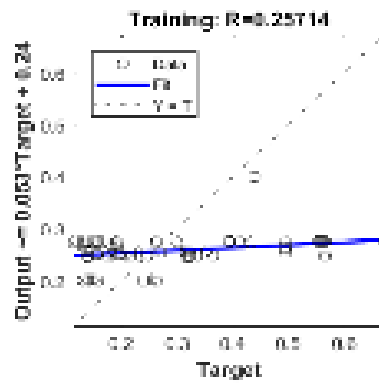

*Reporte del entrenamiento de la ANN con 22 neuronas en la capa oculta como número óptimo de neuronas para la mejor predicción del  $X_{50}$  Teórico*



**Figura 24**

*Graficas Generadas en el entrenamiento de la ANN con 22 neuronas en la capa oculta como número óptimo de neuronas*





Como se aprecia en el gráfico de “Best Validation Performance” tanto a la curva de entrenamiento como la de validación tienen el mismo valor del RMSE y este es inferior al de las otras dos gráficas presentadas en los entrenamientos con 14 y 70 neuronas en la capa oculta de la ANN, lo que significa que el porcentaje de error de este modelo predictivo es casi nulo. Esto lo corroboramos con los RMSE del conjunto de datos usados para los procesos de entrenamiento, validación y prueba de la ANN con las 22 neuronas en la capa oculta como el número óptimo de neuronas a usar en este modelo de predicción.

### Figura 25

*Códigos de programación para determinar el RMSE y evaluar el rendimiento del entrenamiento de la ANN con el número óptimo de neuronas (22)*

```
yTrain=exp(net(xt(:,tr.trainInd)))-1;  
yTrainTrue=exp(yt(tr.trainInd))-1;  
sqrt(mean((yTrain-yTrainTrue).^2))  
yVal=exp(net(xt(:,tr.valInd)))-1;  
yValTrue=exp(yt(tr.valInd))-1;  
sqrt(mean((yVal-yValTrue).^2))  
yTest=exp(net(xt(:,tr.testInd)))-1;  
yTestTrue=exp(yt(tr.testInd))-1;  
sqrt(mean((yTest-yTestTrue).^2))
```

### Figura 26

*RMSE del entrenamiento, validación y prueba de la ANN con número óptimo de neuronas (22) respectivamente*

```
ans = 0.1845
```

```
ans = 0.1902
```

```
ans = 0.1359
```

Como noveno y último paso de este entrenamiento de la ANN y del desarrollo del modelo de predicción, debemos visualizar la predicción hecha por las neuronas en la capa oculta de la ANN.

Esta visualización de la predicción de la ANN como una función de los datos reales, significa que la gráfica nos mostrará la correlación entre los tamaños de roca del Índice de Fragmentación Real  $X_{50\text{Real}}$  (medidos) y los tamaños de roca del Índice de Fragmentación Teórico  $X_{50\text{Teórico}}$  (predichos).

El modelo habrá funcionado en la medida en que los datos medidos ( $X_{50\text{Real}}$ ) sean similares a los datos predichos ( $X_{50\text{Teórico}}$ ).

Los códigos de programación y gráfica obtenida se muestran en las figuras 27 y 28 respectivamente del capítulo de resultados.

En cuanto al análisis de datos, estos serán analizados con métodos estadísticos descriptivos, exploratorios y predictivos, ya que es un campo de investigación novedoso y con aún pocos datos por analizar, sin embargo, estos métodos estadísticos nos permitirán estimar el porcentaje de predicción de la principal tecnología de Inteligencia Artificial, la Red Neuronal Artificial (ANN) siendo los principales lineamientos plasmados para su implementación y los retos metodológicos, de investigación, entendimiento e implementación de novedosas tecnologías.

La investigación finalmente, cumplió con todos los aspectos éticos desarrollados de acuerdo a la normativa, haciendo citas y referencias de manera correcta de acuerdo a la Norma APA 7ta. Edición y teniendo como meta no obtener más del 20% de similitud con otros trabajos, para lo cual, se emplea el uso del Software Turnitin, el cual permite estimar y asegurar lo planteado como meta. Así mismo se presentó resultados reales de acuerdo a la

aplicación de la Red Neuronal Artificial (ANN) en los procesos de voladura en minería superficial, logrando cumplir con los esenciales lineamientos para su implementación y poder analizar los retos que implica su aplicación, especialmente en la predicción del Índice de Fragmentación Media de Roca Volada ( $X_{50}$ ).

Respecto a la aplicación de herramientas y métodos para determinar las tendencias, se evalúan los factores de ponderación, los cuales se obtuvieron con el uso del software Matlab R2017b mediante el análisis de los datos obtenidos y el control del proceso. En este sentido, se presentarán los principales algoritmos usados para la implementación de las Redes Neuronales Artificiales (ANN) resaltando el de mejor resultado a la fecha, así como la propuesta mínima de arquitectura y modelo neuronal, como también las fórmulas de las funciones de activación en cada capa de la ANN para lograr un claro entendimiento de la forma de aplicar esta tecnología.

### CAPÍTULO III: RESULTADOS

**Dando respuesta al objetivo general se busca desarrollar una Red Neuronal Artificial (ANN) para la predicción del Índice de Fragmentación Medio ( $X_{50}$ ) en las operaciones de voladura en minería superficial 2024, haciendo uso de del programa computacional Matlab R2017b.**

Finalmente, mediante el desarrollo de la red neuronal (ANN) se logra una Visualización de las predicciones de las neuronas en la capa oculta de la Red Neuronal Artificial, como último lineamiento, se puede visualizar la predicción de la ANN como una función de los datos reales, esto significa que la gráfica nos mostrará la correlación entre los tamaños de roca del Índice de Fragmentación Real  $X_{50\text{Real}}$  (medidos) y los tamaños de roca del Índice de Fragmentación Teórico  $X_{50\text{Teórico}}$  (predichos).

El modelo habrá funcionado en la medida en que los datos medidos sean similares a los datos predichos.


#### **Figura 27**

*Códigos de programación para la visualización de la predicción de la ANN*

```
plot(yTrainTrue,yTrain,'x'); hold on;  
plot(yValTrue,yVal,'o');  
plot(yTestTrue,yTest,'*')  
plot(0:1,0:1); hold off;
```

**Figura 28**

*Gráfica de predicción de las neuronas en la capa oculta de la ANN en los procesos de entrenamiento (data 1), validación (data 2) y prueba (data 3)*



Cómo se puede apreciar, la mayor cantidad de valores del  $X_{50Real}$  hasta un tamaño de 0.3 m., presentan una gran correlación con los datos del  $X_{50Teórico}$  predichos por la ANN, sin embargo, para valores más altos del  $X_{50Real}$ , la ANN no presenta valores predichos de  $X_{50Teórico}$ , situación que podrá visualizarse y analizarse con mayor detalle analizando la estadística descriptiva.

Por lo que el modelo tiene un gran nivel de predicción, pero aún no es completo porque no se puede generalizar, esto podría mejorar con un mayor número de entrenamientos o mayor número de capas ocultas, hasta lograr un óptimo resultado, pero siempre usando el número óptimo de neuronas ya calculado de 22 en la capa oculta de la ANN.

**Con respecto al primer objetivo específico: Determinar los datos que se usaran como predictores en las operaciones de voladura en minería superficial 2024. Se obtuvo los siguientes resultados**

La investigación desarrollará a detalle los lineamientos para la aplicación de la ANN para predecir el Índice de Fragmentación Teórico ( $X_{50}$ ). Este  $X_{50}$  es importante al permitir mejorar la eficiencia de los otros procesos mineros como el carguío, acarreo, trituración, molienda y flotación, generando un ahorro de energía.

**Tabla 2**

*Datos usados como predictores en la (ANN) para las operaciones de voladura*

S/B	H/B	B/D	T/B	Pf (kg/m <sup>3</sup> )	X <sub>B</sub> (m)	E (GPa)	X <sub>50</sub> real	X <sub>50</sub> predicción
1.24	1.33	27.27	0.78	0.48	0.58	60	0.37	0.31
1.24	1.33	27.27	0.78	0.48	0.58	60	0.37	0.31
1.24	1.33	27.27	0.78	0.48	1.08	60	0.33	0.29
1.24	1.33	27.27	0.78	0.48	1.11	60	0.42	0.35
1.24	1.33	27.27	0.78	0.48	1.08	60	0.46	0.38
1.24	1.33	27.27	1.17	0.27	1.08	60	0.37	0.31
1.24	1.33	27.27	1.06	0.33	1.08	60	0.64	0.49
1.24	1.33	27.27	0.91	0.41	1.11	60	0.42	0.35
1.24	1.33	27.27	0.91	0.41	1.11	60	0.26	0.23
1.24	1.33	27.27	0.99	0.36	1.08	60	0.42	0.35
1.24	1.33	27.27	1.06	0.33	1.11	60	0.31	0.27
1.24	1.33	27.27	1.06	0.33	1.11	60	0.38	0.32
1.17	1.5	26.2	1.12	0.3	0.68	45	0.48	0.39
1.17	1.58	26.2	1.22	0.28	0.68	45	0.48	0.39
1.17	1.96	26.2	1.3	0.34	1.56	45	0.75	0.56
1.17	1.75	26.2	1.31	0.29	1.56	45	0.96	0.67
1.17	1.75	26.2	1.16	0.36	1.56	45	0.76	0.57
1.17	1.67	26.2	1.22	0.31	1.80	45	0.53	0.43
1.17	1.83	26.2	1.34	0.3	1.80	45	0.56	0.44
1.17	1.83	26.2	1.29	0.32	1.80	45	0.74	0.55
1.17	1.83	26.2	1.23	0.35	1.80	45	0.44	0.36
1	2.67	27.27	0.89	0.75	0.83	50	0.23	0.21
1	2.67	27.27	0.89	0.75	0.78	50	0.25	0.22
1	2.4	30.3	0.8	0.61	1.02	50	0.27	0.24
1	2.4	30.3	0.8	0.61	0.75	50	0.3	0.26
1.1	2.4	30.3	0.8	0.55	1.18	50	0.38	0.32
1.1	2.4	30.3	0.8	0.55	1.24	50	0.37	0.31
1.1	2.4	30.3	0.8	0.55	1.33	50	0.38	0.32
1.13	5	39.47	1.93	0.31	2.00	45	0.64	0.49
1.2	6	32.89	3.67	0.3	2.00	45	0.54	0.43

1.2	6	32.89	3.7	0.3	2.00	45	0.51	0.41
1.2	6	32.89	4.67	0.22	2.00	45	0.64	0.49
1.2	6	32.89	3.11	0.35	2.00	45	0.54	0.43
1.2	6	32.89	3.22	0.34	2.00	45	0.69	0.52
1.2	6	32.89	0.8	0.49	1.67	32	0.17	0.16
1.2	6	32.89	0.8	0.51	1.67	32	0.17	0.16
1.2	6	32.89	0.8	0.49	1.67	32	0.13	0.12
1.2	6	32.89	0.8	0.52	1.67	32	0.17	0.16
1.2	6	32.89	0.8	0.42	1.67	32	0.13	0.12
1.4	6	32.89	0.8	0.36	1.67	32	0.15	0.14
1.2	6	32.89	0.6	0.56	1.03	32	0.18	0.17
1.4	6	32.89	0.6	0.3	1.03	32	0.19	0.17
1.4	6	32.89	0.6	0.35	1.03	32	0.16	0.15
1.16	5	39.47	0.5	0.39	1.03	32	0.17	0.16
1.16	5	39.47	0.5	0.32	1.03	32	0.21	0.19
1.25	3.5	20	1.75	0.73	1.00	9.57	0.44	0.36
1.25	5.1	20	1.75	0.7	1.00	9.57	0.76	0.57
1.38	3	20	1.75	0.62	1.00	9.57	0.35	0.30
1.5	5.5	20	1.75	0.56	1.00	9.57	0.55	0.44
1.75	4.75	20	1.75	0.39	1.00	9.57	0.35	0.30
1.25	4.75	20	1.75	0.33	1.00	9.57	0.23	0.21
1.25	5	20	1.75	0.44	1.00	9.57	0.4	0.34
1.2	2.4	25	1.4	0.28	0.50	9.57	0.35	0.30
1.4	3.2	25	1.4	0.31	0.50	9.57	0.29	0.25
1.25	2.5	28.57	0.83	0.42	0.50	13.25	0.15	0.14
1.25	2.5	28.57	0.83	0.42	0.50	13.25	0.19	0.17
1.25	2.5	28.57	0.83	0.42	0.50	13.25	0.23	0.21
1.25	2.5	28.57	0.83	0.42	1.50	13.25	0.22	0.20
1.25	2.5	28.57	0.83	0.42	1.50	13.25	0.24	0.22
1.25	2.5	28.57	0.83	0.42	1.50	13.25	0.26	0.23
1.25	2.5	28.57	0.83	0.42	1.50	13.25	0.28	0.25
1.2	4.4	28.09	1.2	0.58	0.77	16.9	0.15	0.14
1.2	4.8	28.09	1.2	0.66	0.56	16.9	0.17	0.16
1.2	4.8	28.09	1.2	0.72	0.29	16.9	0.14	0.13
1.2	4	28.09	1.6	0.49	0.81	16.9	0.16	0.15
1.14	6.82	24.72	1.36	0.84	1.43	16.9	0.21	0.19
1.14	6.36	24.72	1.36	0.82	1.77	16.9	0.21	0.19
1.25	3.5	22.47	1.25	0.75	1.03	16.9	0.15	0.14
1.25	3.25	22.47	1.25	0.71	0.83	16.9	0.19	0.17
1.25	3.5	22.47	1.25	0.76	1.68	16.9	0.18	0.17
1.25	3.5	22.47	1.25	0.76	1.24	16.9	0.15	0.14
1.14	3.18	24.72	1.14	0.69	0.67	16.9	0.14	0.13
1.14	3.18	24.72	1.14	0.69	2.01	16.9	0.2	0.18
1.12	2.8	28.09	1	0.54	0.96	16.9	0.15	0.14
1	2.4	28.09	1	0.56	0.83	16.9	0.14	0.13
1.1	3.75	21.74	1	1.02	1.64	16.9	0.15	0.14
1.1	3.5	22.47	1.25	0.86	2.35	16.9	0.15	0.14
1.25	3.75	17.98	1.56	1.24	1.53	16.9	0.19	0.17
1	4	18.42	1.71	1.26	0.73	16.9	0.15	0.14
1	4	18.42	1.71	1.26	1.47	16.9	0.17	0.16
1.14	4	18.42	1.71	1.1	1.19	16.9	0.19	0.17
1.11	4.44	18.95	1.67	1.25	1.71	16.9	0.22	0.20

1.28	3.61	18.95	1.67	0.89	0.56	16.9	0.2	0.18
1	2.83	33.71	1	0.48	0.45	15	0.27	0.24
1.2	2.4	28.09	1	0.53	0.86	15	0.14	0.13
1.2	2.4	28.09	1	0.53	0.44	15	0.14	0.13
1.25	4.5	22.47	1.5	0.76	0.66	15	0.2	0.18
1.11	3.33	30.34	1.11	0.47	0.47	15	0.17	0.16
1.2	3.2	28.09	1.2	0.48	1.11	15	0.3	0.26
1.2	2.4	28.09	1	0.7	0.88	15	0.12	0.11

**Nota:** En la tabla 2 se presentan 90 datos recopilados de voladura del investigador Aler et al. (1996) y Hamdi et al. (2001), de investigaciones realizadas en las minas de Enusa y Reocín localizadas en España, datos recolectados de voladuras, referente al significado de las siglas se encuentra en la tabla 1.

**Respecto al Segundo objetivo específico: Determinar los predictores que tienen mayor correlación con el resultado esperado usando la estadística descriptiva de la Red Neuronal Artificial (ANN) haciendo uso del programa computacional Minitab.**

En esta sección analizamos las hipótesis nula y alternativa, analizando la respuesta de cada uno de los predictores en el resultado esperado del Índice de Fragmentación y poder determinar si todas influyen por igual en el resultado, o alguno de ellos tiene una mayor influencia en la respuesta.

**Figura 29**

*Resultados de ANOVA unidireccional*

**ANOVA unidireccional: H/S; H/B; B/D; T/B; Pf; XB; E**

Método

Hipótesis nula                      Todas las medias son iguales  
 Hipótesis alterna                  Por lo menos una media es diferente  
 Nivel de significancia           $\alpha = 0.05$

Se presupuso igualdad de varianzas para el análisis.

Información del factor

Factor	Niveles	Valores
Factor	7	H/S; H/B; B/D; T/B; Pf; XB; E

Análisis de Varianza

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Factor	6	97292	16215.3	332.13	0.000
Error	623	30416	48.8		
Total	629	127708			

Nota: En este caso el nivel de significancia es  $\alpha = 0.05$  y usando la regla de decisión con el valor de  $p = 0.000$  mostrado en el análisis de varianza, valor menor al de alfa ( $\alpha$ ), podemos aceptar la hipótesis alternativa y concluir que al menos uno de los 7 predictores influye en mayor medida en la predicción del Índice de Fragmentación ( $X_{50}$ ).

En cuanto al resumen del modelo podemos identificar el valor del  $R^2$ , el  $R^2$  ajustado y el  $R^2$  esperado.

**Figura 30**

*Resumen del modelo*

Resumen del modelo

S	R-cuad.	R-cuad. (ajustado)	R-cuad. (pred)
6.98727	76.18%	75.95%	75.64%

En los 3 datos podemos notar que el valor es superior al 75% lo que indica que la predicción de los datos usados con los siete predictores, tienen un buen valor de predicción del Índice de Fragmentación ( $X_{50}$ ). Como conclusión, el valor de  $R^2$  esperado = 75.64% es un buen valor de predicción.

El análisis de las medias, nos permite determinar tanto la media, la desviación estándar y los intervalos de confianza de las medias para los 90 valores de cada uno de los predictores.

**Figura 31**

*Análisis de las Medias, desviación estándar e Intervalos de Confianza*

Medias

Factor	N	Media	Desv.Est.	IC de 95%
H/S	90	1.2018	0.1101	(-0.2446; 2.6481)
H/B	90	3.459	1.639	( 2.013; 4.905)
B/D	90	27.216	4.798	( 25.770; 28.663)
T/B	90	1.2676	0.6917	(-0.1788; 2.7139)
Pf	90	0.5366	0.2392	(-0.9098; 1.9829)
XB	90	1.1787	0.4792	(-0.2677; 2.6250)
E	90	30.59	17.76	( 29.14; 32.03)

Desv.Est. agrupada = 6.98727

Analizando los resultados, podemos notar que todas las medias de cada uno de los 7 predictores son diferentes al igual de sus intervalos de confianza, reafirmando con esto la hipótesis alternativa que ya nos indicaba la probabilidad de que al menos uno de los predictores influye de manera más significativo en los resultados de la predicción del Índice de Fragmentación Teórico ( $X_{50Teórico}$ ).

Sin embargo, para determinar cuál o cuáles de los 7 predictores son los que mayor influencia tienen en este resultado de predicción, es necesario realizar una prueba de comparación.

### Figura 32

*Prueba de comparación usada: Parejas de Tukey*

#### Comparaciones en parejas de Tukey

Agrupar información utilizando el método de Tukey y una confianza de 95%

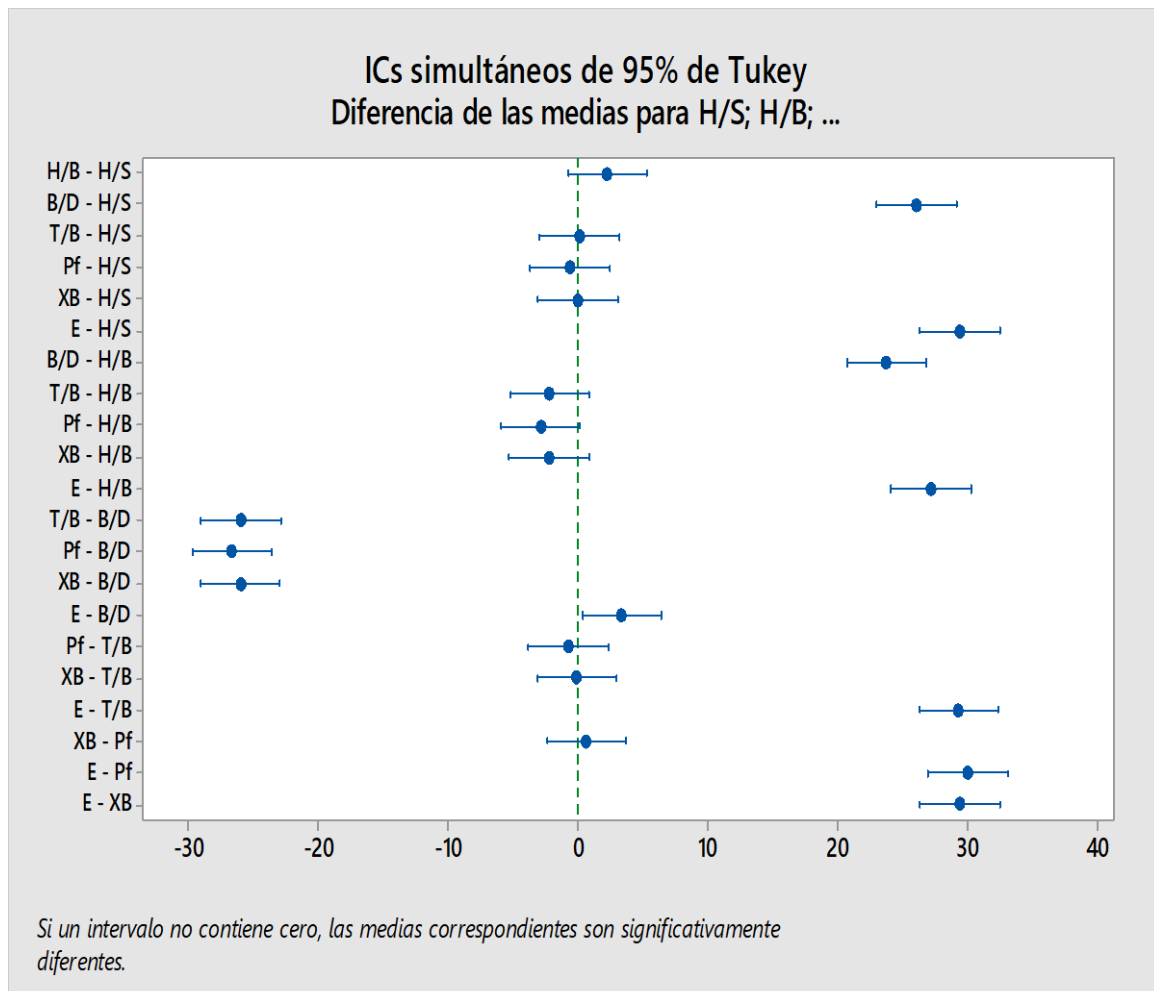
Factor	N	Media	Agrupación
E	90	30.59	A
B/D	90	27.216	B
H/B	90	3.459	C
T/B	90	1.2676	C
H/S	90	1.2018	C
XB	90	1.1787	C
Pf	90	0.5366	C

Las medias que no comparten una letra son significativamente diferentes.

En este análisis comparativo de estadística inferencial podemos apreciar que las medias de los predictores E (elasticidad) y B/D (Diámetro del taladro de carga) son significativamente distintas a las medias de los otros 5 predictores, pudiendo concluir que son estos los predictores de mayor influencia en la predicción del Índice de Fragmentación Teórico ( $X_{50Teórico}$ ).

**Figura 33**

*Gráfico de la Diferencia de Medias*




En esta gráfica se puede apreciar con mayor facilidad que las comparaciones de los predictores E y B/D con los otros predictores no contienen el valor de cero “0” en sus Intervalos de Confianza por lo que, al ser comparados con otros predictores, se puede concluir que, en efecto, sus medias son significativamente diferentes a los otros predictores.

**Respecto al tercer objetivo específico: Analizar las gráficas resultantes para determinar el nivel de predicción del Índice de Fragmentación Medio ( $X_{50}$ ), Describiendo los principales retos del entrenamiento de la Red Neuronal Artificial en las operaciones de voladura en minería superficial 2024**

Mediante los resultados obtenidos se puede apreciar en el gráfico de los Intervalos de Confianza con un 95% de nivel de confianza.

**Figura 34**

*Intervalos de Confianza al 95% del Nivel de Confianza*




En el gráfico podemos apreciar que los Intervalos de Confianza de los predictores B/D (Diámetro del Taladro de Carga) y E (Módulo de Elasticidad) no traslapan con los Intervalos de Confianza de los otros predictores, reforzando aún más la conclusión del grado de influencia que estos predictores tienen en los resultados del Índice de Fragmentación Teórico ( $X_{50\text{Teórico}}$ ).

El gráfico de valores individuales también nos sirve para entender el proceso de agrupación de los datos alrededor de las medias.

**Figura 35**

*Gráfico de Valores Individuales*

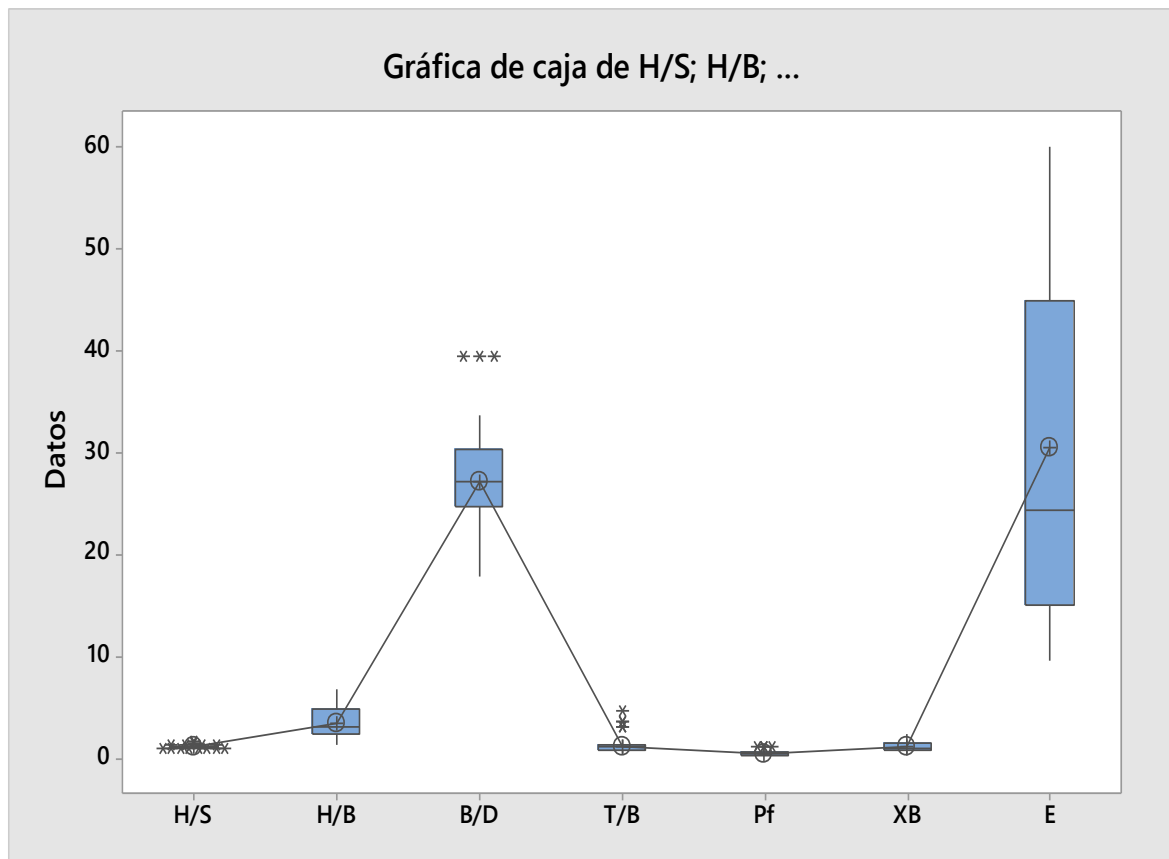


Nota: En este podemos notar que los mismos predictores E (Módulo de Elasticidad) y B/D (Diámetro del Taladro de Carga) tienen sus datos individuales completamente dispersos en relación a su media, caso que no sucede en los otros predictores en donde sus valores individuales están agrupados alrededor de su media.

El diagrama de Caja de Bigotes muestra también la distribución de las medianas y los cuartiles de cada uno de los predictores y nos confirma que los predictores sobre los cuales se debe poner mayor atención son el E (Módulo de Elasticidad) y el B/D (Diámetro del Taladro de Carga).

**Figura 36**

*Diagrama de caja Bigotes*

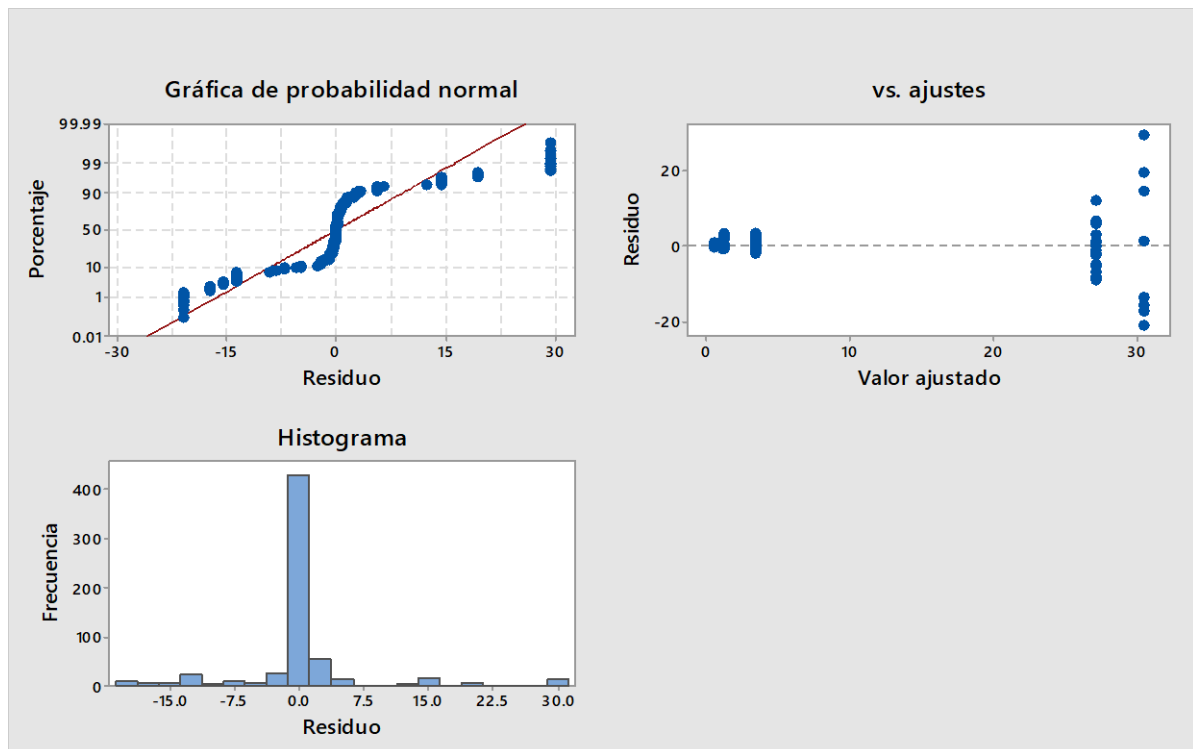


Nota: Son estos dos predictores, lo que en cada una de las gráficas confirman la necesidad de establecer métodos para mejorar su aplicación en campo durante los procesos de voladura.

Finalmente, los grafica de residuales o tres en uno, nos permitirán confirmar los supuestos del Análisis de Varianza.

**Figura 37**

*Grafica de residuales o tres en uno*



En el primero de los gráficos de probabilidad de la normal, podemos notar que los datos no se ajustan a la normalidad, confirmando la necesidad de hacer la normalización de los datos antes de usarse para el entrenamiento, validación y prueba de la ANN, paso que se explicó en el paso 3 del capítulo de Metodología, con esto, logramos que el entrenamiento, validación y prueba de la ANN arrojen resultados de predicción con un alto nivel de correlación en comparación con los datos medidos en campo.

El segundo de gráfico de Residuales Vs. Ajustes, entendiendo que los residuales son la diferencia entre respuestas medidas y las respuestas predichas y nos permiten verificar la distribución aleatoria de los residuos y que las varianzas con constantes. En la misma se puede apreciar que la distribución es a ambos lados de la línea de referencia y nos muestra

un patrón de distribución de los datos hacia los mínimos y máximos valores de 0 a 5 y de 25 a 30 en su valor ajustado.

En el gráfico de histograma, se vuelve a confirmar la necesidad de normalizar los datos antes del entrenamiento de la ANN, pues estos no se agrupan de manera correcta en los intervalos impidiendo esta distribución no normal que impide mostrar la formación de la campana de Gauss.

Se continua con la descripción de los principales retos para la implementación de la ANN en la mecánica de rocas en especial en la predicción del Índice Medio de Fragmentación Teórico ( $X_{50}$ ) en los procesos de perforación y voladura son:

- Necesidad de conocimiento previo para poder enseñar o alimentar a la ANN.
- La limitada disponibilidad de datos para realizar las simulaciones con ANN.
- La validación de los modelos de ANN.
- Insuficiente información sobre el comportamiento del macizo rocoso.
- Escasa información entre la roca huésped y las estructuras.
- Variabilidad inherente en el material y las propiedades físico mecánicas del macizo rocoso.

La arquitectura de la ANN usada para predecir el tamaño el  $X_{50}$  teórico es compleja y difícil de aplicar de forma práctica, si no se cuenta con entrenamiento y conocimientos específicos. La selección de los parámetros usados en el entrenamiento de la ANN no siempre asegurará el resultado esperado, más aún si estos no son normalizados. siendo muy variados los parámetros que se decidan usar para este fin. Los parámetros como la cohesión, resistencia al corte, ángulo de fricción, altura y ángulo de pendiente, presión del agua y fuerza sísmica plantean un reto para la correcta estimación de la estabilidad de la roca usando la ANN.

La aplicación de estos modelos no es fácil y requiere ejecutar otros experimentos de laboratorio y modelos por no tener una ecuación simple como los modelos de regresión, existiendo la posibilidad de obtener resultados diferentes en cada nuevo modelamiento.

Es por tanto importante aplicar otros modelos híbridos de la inteligencia artificial como ANFIS, PSO-ANN, SVM-ANN, GA-ANN e ICA ANN para lograr predicciones contrastables con las predicciones de la IA ANN y obtener datos para una óptima fragmentación. Esto reduce los costos de usar el análisis de imágenes.

Otro reto importante de analizar, está referido al hecho de que estos modelos no se pueden aplicar a minas con características similares puesto que no se trata de un modelo matemático/empírico sino específico a cada proceso, estos modelos de computación blanda podrían convertirse en un ejercicio de gabinete sin tener una aplicación práctica.

La capacidad de aprendizaje y memoria de la red también es un reto importante de analizar, por lo que, si se obtienen datos nuevos de las pilas de material volado, la ANN debe reconstruirse desde cero. Esto obliga a tomar una decisión adecuada entre dos conceptos importantes, la arquitectura de la red por un lado y el algoritmo de aprendizaje por el otro, errores en su elección resultarían en predicciones alejadas de la realidad.

Para optimizar y reducir el error cuadrático medio (MSE) entre el valor esperado y el real, y maximizar así la velocidad de entrenamiento es necesario realizar ciclos de entrenamiento de entre 300 y 500, lo que genera un consumo de tiempo para validar la predicción de la ANN. La variedad de las voladuras también afecta la eficiencia o no de las predicciones de la ANN sobre todo en lo referido a su versatilidad y confiabilidad, esto también se analiza cuando se tienen parámetros incontrolables como los referidos a la mecánica de rocas, mismos que podrían generar una alta tasa de error en la predicción de la ANN.

## CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES

En la presente investigación se obtuvo que, al menos uno de los 7 predictores influye en mayor medida en la predicción del Índice de Fragmentación ( $X_{50}$ ), ya que mediante el desarrollo de la ANN empleando el Matlab R2017b, se mantiene una correlación directa entre los predictores y el Índice de Fragmentación Medio ( $X_{50}$ ) de forma que se encontró resultados óptimos para el desarrollo de las operaciones de voladura en minería superficial 2024; por lo que se acepta la hipótesis alternativa en la cual al menos uno de los 7 predictores influye en la predicción del Índice de Fragmentación ( $X_{50}$ ) pretendiendo demostrar que el nivel de predicción de la ANN, es cercano al Índice de Fragmentación Medio Real.

La implicancia más resaltante del desarrollo de esta investigación, es que se obtuvo soluciones de predicciones que estimen cual es el grado de fragmentación del macizo rocoso durante el proceso de explotación en operación mineras superficiales, de tal manera que se desarrollen los grados de evolución de la red neuronal, se aumente el nivel de precisión y así obtener una óptima fragmentación, de igual forma mediante el uso de la IA, específicamente la implementación de Redes Neuronales Artificiales (ANN) en los procesos mineros y en específico en el proceso de perforación y voladura ha sido analizado a profundidad en este documento dando todos los lineamientos mínimos requeridos para entender su proceso de implementación como también los retos que la Red presenta de forma que la información obtenida, sirva para usarse como bases de datos para entrenar, validar la ANN y posterior a ello usar la data obtenida en empresas mineras con características similares a los datos de estudio y asegurar de igual manera un resultado óptimo esperado en su nivel de predicción, sirva de beneficio para proyectos futuros.

Según Sánchez (2020), tuvo como resultados una serie de parámetros los cuales pueden ser controlables e incontrolables y los mismos son usados como los parámetros de ingreso o predictores para generar el entrenamiento, validación y prueba de la ANN, situación que permite desarrollar un modelo altamente eficiente en la predicción del índice de fragmentación mismo que se puede añadir gracias al análisis del error cuadrático medio y el coeficiente de correlación  $R^2$ . El estudio coincide con la investigación ya que en ella se presenta los lineamientos de manera clara y sencilla, para hacerla entendible al implementar una ANN, tomando como referencia el modelo diseñado en este estudio, dos capas ocultas, presenta una capa de salida, teniendo 6 neuronas o perceptores en el ingreso, 18 neuronas en las capas ocultas y una neurona en la capa de salida con el fin de obtener predicciones del el Índice Medio de Fragmentación ( $X_{50}$ ).

En la investigación de Xie (2021) obtuvo como resultados una combinación de la técnica de redes neuronales artificiales en la cual se utiliza modelos de predicción computacional de software para optimizar los parámetros de voladura. El 80% de los datos recopilados se utilizó para el desarrollo y el 20% para pruebas del modelo. El cual difiere de la presente investigación ya que en nuestro estudio se obtuvo que la ANN es un método completamente valido y con valores de Coeficiente de Regresión muy cercanos a la unidad, lo que hacen entender que existe una fuerte relación entre los datos esperados producto de la aplicación de la ANN y los datos reales obtenidos en los procesos de voladura.

En el estudio de Hyder et al. (2019), obtuvo como resultado que la ANN permite obtener procesos más seguros y eficientes, reduciendo los costos generados por un mal proceso de voladura como lo cita en el capítulo de antecedentes. Este estudio coincide con la investigación ya que en ella se desarrolló una evaluación de proceso la cual es vital para

asegurar la seguridad de la operación, pues presenta fenómenos importantes de analizar tanto para el aspecto comercial como la seguridad de las labores.

En la investigación de López (2019), obtuvo como resultado un modelo de distribución de fragmentos de producto explosivo  $X_{50}$  y  $X_{80}$ , usan ecuaciones que describen la distribución del tamaño de las partículas proporcionado por el software utilizando el método de análisis estadístico, se obtuvo un intervalo de confianza aceptable del 95%. El cual coincide con la presente investigación ya que en nuestro estudio se obtuvo que la ANN se usó para evaluar la estabilidad del macizo rocoso y en el caso de estudio se usó para la evaluación del Índice Medio de Fragmentación ( $X_{50}$ ) demostrando la versatilidad en el uso de la ANN.

En el estudio de Mendoza (2021), se obtuvo como resultado un sistema predictivo para la fragmentación de roca está basado en aplicar tecnología durante la voladura de roca, emplea con siete variables como parámetros para predecir una explosión ( $D$ ,  $S/B$ ,  $H/B$ ,  $T/B$ ,  $P_f$ ,  $E$ ,  $X_B$ ,  $X_{50}$ ), como factor de potencia se considera al explosivo. Obteniendo como resultado que el factor de potencia está relacionado con el peso (kg) del explosivo utilizado con el volumen de roca detonante ( $m^3$ ). El cual difiere de la presente investigación ya que en nuestro estudio se obtuvo que con el estudio propuesto permite trabajar con una serie de parámetros y poder predecir escenarios o comportamientos de los procesos de voladura como el tamaño de la fragmentación, las vibraciones del suelo producto de las explosiones, el flasrock, el rockbrun y la estabilidad de las estructuras a través del análisis de las propiedades mecánicas de las rocas.

Nuestros resultados contrastan con Kulatilake et. al (2010) que los algoritmos se pueden obtener a través de números experimentales para minimizar el MSE entre el valor predicho y el valor esperado y para maximizar la velocidad de entrenamiento y la estabilidad

del MSE calculado con el número de ciclos de entrenamiento. No hay una base teórica universalmente aceptada para elegir la red geométrica; por lo tanto, en el uso práctico, debe obtenerse a través de experimentación numérica como se muestra en la investigación para minimizar el RMSE obtenido entre la predicción y el valor medido. Este aumentará la carga de trabajo cuando se utilice el enfoque de red neuronal. La capacidad de aprendizaje y memoria de una red neuronal depende de las muestras de entrenamiento utilizadas. Por lo tanto, si se dispone de nuevos datos, para obtener predicciones precisas, la red debe reconstruirse nuevamente a partir del principio. Si coincide con la investigación ya que mediante el análisis del MSE permite entender si el entrenamiento es el correcto.

La investigación presenta como limitante metodológica el involucramiento, comprensión y entendimiento del significado de los algoritmos de entrenamiento de las ANN, estos no sólo son complejos en su fórmula empírica, sino que requieren de un conocimiento avanzado de matemáticas. En este sentido, una implicancia teórica del estudio, reafirma el uso del algoritmo de Levenberg-Marquardt (LM), como uno de los más sencillos de aplicación, entendimiento, pero sobre todo con gran capacidad de entrenamiento para la ANN, lo que asegura un óptimo proceso de predicción.

La principal dificultad metodológica ha sido conseguir la base de datos de procesos de voladura, pues son datos que no son brindados por las operaciones mineras, sin embargo, como ya se mencionó, el uso de buscadores académicos muchas veces restringe su acceso a la información al respecto.

Por otro lado, como limitante operativa más importante se debe citar la necesidad de contar con data en tiempo real y no sólo esperar a obtenerla de la pila de material volado, aun así, de recurrir a esta forma de obtención, debería usarse software avanzados de procesamiento de imágenes y no sólo de conteo manual o visual.

## CONCLUSIONES

Se desarrolló una Red Neuronal Artificial (ANN) para la predicción del Índice de Fragmentación Medio ( $X_{50}$ ) en las operaciones de voladura en minería superficial, con el programa computacional Matlab R2017b, obteniéndose al menos uno de los 7 predictores influye en mayor medida en la predicción del Índice de Fragmentación ( $X_{50}$ ); mediante el desarrollo de la ANN, se obtuvo una correlación directa entre los predictores y el Índice de Fragmentación Medio ( $X_{50}$ ) de forma que se logró obtener resultados óptimos.

Se determinó que los datos usados como predictores fueron un total de 90 en las operaciones de voladura en minería superficial, para la predicción del Índice Medio de Fragmentación Teórico ( $X_{50\text{predicción}}$ ), se obtuvo la correlación de estos con los obtenidos en las mediciones de campo de voladura ( $X_{50\text{REAL}}$ ).

Se estableció que los predictores con mayor correlación utilizando la estadística descriptiva de la Red Neuronal Artificial (ANN) y empleando el programa computacional Minitab, podemos apreciar que las medias de los predictores E (elasticidad) y B/D, son significativamente distintas a las medias de los otros 5 predictores, concluyendo que, son estos los predictores de mayor influencia en la predicción del Índice de Fragmentación ( $X_{50}$ ).

Finalmente se analizó los gráficos resultantes para determinar el nivel de predicción del índice de Fragmentación Medio ( $X_{50}$ ), los intervalos de confianza con un 95%, los predictores B/D y E no traslapan con los intervalos de confianza de los otros predictores; de igual forma, se concluye que los primordiales desafíos en el entrenamiento de redes neuronales artificiales en operaciones de voladura, se tiene a la preservación de la secuencia, es relevante el conocimiento previo, el diseño y alimentación de la red neuronal artificial y la limitada disponibilidad de datos simulados, revalidación de modelos, conducta de la matriz rocosa, tener una arquitectura eficiente en la ANN para predicción del tamaño  $X_{50}$ .

## RECOMENDACIONES

Se recomienda al área de ore control contar con Conocimiento previo del software estadístico Minitab 17 o Matlab 17 para poder desarrollar estructuras de red utilizadas para crear estadísticas descriptivas de los datos y crear los modelos predictivos necesarios.

Se recomienda que los encargados de monitorear los procesos identifiquen con precisión los ciclos que se establecen en el entrenamiento de forma que se puedan lograr una ANN optimizada, cabe recalcar que esto procedimientos pueden ser muy extensos, pero son necesarios para poder realizar la validación de ANN, la cual puede varias de acuerdo al ciclo de repetición.

Finalmente, se hace la recomendación a futuros estudios, que logren verificar los análisis de varianza y así logren adquirir una excelente validación de datos en la ANN y así plantear comparaciones en base a los datos medidos en el área real ( $X_{50}$  real), se recomienda el uso continuo de esquemas, gráficos, y principalmente el uso de la estadística para obtener una mejor identificación.

## REFERENCIAS

- Ballantyne, G. (2019). *Quantifying the additional energy consumed by ancillary equipment and embodied in grinding media in comminution circuits*. Conference. Vancouver, Canadá. <https://www.ceecthefuture.org/resources/quantifying-the-additional-energy-con>.
- Carranza. (2022) *Innovaciones en nuevas tecnologías empleadas en minería superficial*. 10.1051/e3sconf/201913504026
- Cochilco. (2019). *Proyección del consumo de energía eléctrica en la minería del cobre*. <https://www.cochilco.cl/Mercado%20de%20Metales/Proyecci%C3%B3n%20Consumo%20EE%202019-2030.pdf>.
- Dhekne, P., Pradhan, M., & Jade, R. K. (2016). *Assessment of the effect of blast hole diameter on the number of oversize boulders using ANN model*. Journal of the Institution of Engineers (India) Series D, 97(1), 21–31. <https://doi.org/10.1007/s40033-015-0083-7>
- Guha Roy, D., & Singh, T. N. (2020). *Predicting deformational properties of Indian coal: Soft computing and regression analysis approach*. Measurement: Journal of the International Measurement Confederation, 149(106975), 106975.
- Hyder, Z., Siau, K., & Nah, F. (2019). *Artificial intelligence, machine learning, and autonomous technologies in mining industry*. Journal of database management, 30(2), 67–79. <https://doi.org/10.4018/jdm.2019040104>
- Isleyen, E., Duzgun, S., & McKell Carter, R. (2021). *Interpretable deep learning for roof fall hazard detection in underground mines*. Journal of Rock Mechanics and Geotechnical Engineering, 13(6), 1246–1255. <https://doi.org/10.1016/j.jrmge.2021.09.005>
- Linares, L. R. (2019). *Un nuevo enfoque predictivo de la fragmentación en la Voladura de Rocas*. Industrial Data, 21(1):17. recuperado de: 10.15381/idata.v21i1.14907.
- Moomivand Amini Khoshalan, H. S. (2022). *Development of new comprehensive relations to assess rock fragmentation by blasting for different open-pit mines using GEP algorithm and MLR procedure*. 56. 401-41

[https://www.researchgate.net/figure/Parameters-of-GEP-model-for-prediction-of-X20-X50-and-X80\\_tbl3\\_363541249](https://www.researchgate.net/figure/Parameters-of-GEP-model-for-prediction-of-X20-X50-and-X80_tbl3_363541249)).

- Rosales-Huamani, J., Pérez-Alvarado, R., Rojas-Villanueva, U., & Castillo-Sequera, J. (2020). *Diseño de un modelo predictivo de rotura de roca por voladura utilizando redes neuronales artificiales*. 12 , 1405.
- Sampieri, H. (2014). *Influencia de las redes neurinales en la proyección de voladura en minera*. Perú. Minas y tecnología.
- Suzuki, K., & Morales, L. (2021). *Importancia e impactos de la fragmentación en la cadena productiva*. Chile, <https://minas.uchile.cl/noticias/182792/importancia-e-impactos-de-la-fragmentacion-en-la-cadena-productiva>.
- Taiwo Olamide, B. A. (2023). Desarrollo de modelos matemáticos basados en redes neuronales artificiales para predecir el factor de polvo de cantera a pequeña escala para una fragmentación eficiente junto con un modelo de índice de unifomidad. 10.1007/s10462-023-10524-1.
- Xie, C., Nguyen, H., Bui, X.-N., Choi, Y., Zhou, J., & Nguyen-Trang, T. (2021). *Predicción de la distribución del tamaño de las rocas en la voladura de minas utilizando varios modelos novedosos de computación blanda basados en algoritmos de aprendizaje automático*. *Geociencias*.
- Y., A., Bakri, A., & Sazid, M. (2021). *Aplicación de redes neuronales artificiales (RNA) para la predicción y optimización de impactos inducidos por explosiones Minería*. 1 (3), 315-334. <https://doi.org/10.3390/mining1030020> .
- Hyder, Z., Siau, K., & Nah, F. (2019). *Artificial intelligence, machine learning, and autonomous technologies in mining industry*. *Journal of database management*, 30(2), 67–79. <https://doi.org/10.4018/jdm.2019040104>

## Anexos

### Anexo 1

#### Instrumentos de recolección de datos

Instrumento 1: Ficha de análisis documental de los datos de IA (ANN) para predecir el Índice de Fragmentación Medio ( $X_{50}$ ) de roca.

Neuronas o Perceptores en el ingreso	$X_{50}$ real	$X_{50}$ predicción
1		
2		
3		
4		
5		
6		
7		
8		
9		
10		
11		
12		
13		
14		
15		
16		
17		
18		
19		
20		